

Эндрю Ферлитш

Шаблоны и практика глубокого обучения

Deep Learning Patterns and Practices

ANDREW FERLITSCH



MANNING
Shelter Island

Шаблоны и практика глубокого обучения

ЭНДРЮ ФЕРЛИТШ



Москва, 2022

УДК 004.85
ББК 32.971.3
Ф43

Ферлитш Э.

Ф43 Шаблоны и практика глубокого обучения / пер. с англ. А. В. Логунова. – М.: ДМК Пресс, 2022. – 538 с.: ил.

ISBN 978-5-93700-113-9

В книге рассматриваются актуальные примеры создания приложений глубокого обучения с учетом десятилетнего опыта работы автора в этой области. Вы сэкономите часы проб и ошибок, воспользовавшись представленными здесь шаблонами и приемами. Проверенные методики, образцы исходного кода и блестящий стиль повествования позволят с увлечением освоить даже непростые навыки. По мере чтения вы получите советы по развертыванию, тестированию и техническому сопровождению ваших проектов.

Издание предназначено для инженеров машинного обучения, знакомых с Python и глубоким обучением.

УДК 004.85
ББК 32.971.3

Original English language edition published by Manning Publications USA. Russian-language edition copyright © 2022 by DMK Press. All rights reserved.

Все права защищены. Любая часть этой книги не может быть воспроизведена в какой бы то ни было форме и какими бы то ни было средствами без письменного разрешения владельцев авторских прав.

Оглавление

Часть I ■ ОСНОВЫ МАШИННОГО ОБУЧЕНИЯ	25
1 ■ Конструирование современного машинного обучения	26
2 ■ Глубокие нейронные сети	46
3 ■ Сверточная и остаточная нейронные сети	75
4 ■ Основы процесса тренировки	106
Часть II ■ БАЗОВЫЙ ШАБЛОН КОНСТРУИРОВАНИЯ	163
5 ■ Шаблон процедурного конструирования	165
6 ■ Широкие сверточные нейронные сети	199
7 ■ Альтернативные шаблоны связности	235
8 ■ Мобильные сверточные нейронные сети	263
9 ■ Автокодировщики	309
Часть III ■ РАБОТА С КОНВЕЙЕРАМИ	336
10 ■ Гиперпараметрическая настройка	338
11 ■ Перенос обучения	369
12 ■ Распределения данных	396
13 ■ Конвейер данных	420
14 ■ Конвейер тренировки и развертывания	467

Содержание

<i>Предисловие</i>	13
<i>Признательности</i>	14
<i>Об этой книге</i>	15
<i>Об авторе</i>	22
<i>Об иллюстрации на обложке</i>	24

Часть I ОСНОВЫ МАШИННОГО ОБУЧЕНИЯ

1 Конструирование современного машинного обучения

1.1 Курс на адаптируемость	27
1.1.1 Компьютерное зрение задает тон	29
1.1.2 За пределами компьютерного зрения: обработка ЕЯ, понимание ЕЯ, структурированные данные	30
1.2 Эволюция подходов, основанных на машинном обучении	31
1.2.1 Классический ИИ против узкого ИИ	31
1.2.2 Следующие шаги в компьютерном обучении	35
1.3 Выгоды от шаблонов конструирования	42
Резюме	45

2 Глубокие нейронные сети

2.1 Основы нейронных сетей	47
2.1.1 Входной слой	47
2.1.2 Глубокие нейронные сети	50
2.1.3 Сети прямого распространения	51
2.1.4 Метод последовательного API	51
2.1.5 Метод функционального API	52
2.1.6 Входная форма и входной слой	52
2.1.7 Плотный слой	53
2.1.8 Активационные функции	55
2.1.9 Сокращенный синтаксис	59

2.1.10	Повышение точности с помощью оптимизатора.....	60
2.2	Двоичный классификатор в форме глубокой нейронной сети	61
2.3	Мультиклассовый классификатор в форме глубокой нейронной сети	63
2.4	Мультиметочный мультиклассовый классификатор в форме глубокой нейронной сети	66
2.5	Простой классификатор изображений	68
2.5.1	Разглаживание	69
2.5.2	Переподгонка и отсев	71
	Резюме	73

3	Сверточная и остаточная нейронные сети	75
3.1	Сверточные нейронные сети	76
3.1.1	Зачем для моделирования изображений использовать сверточную нейросеть поверх глубокой нейросети	77
3.1.2	Отбор с пониженной частотой (изменение размера).....	77
3.1.3	Обнаружение признаков	79
3.1.4	Сведение	82
3.1.5	Разглаживание	83
3.2	Конструкция в форме ConvNet для сверточной нейросети	83
3.3	Сети в форме VGG	88
3.4	Сети в форме ResNet.....	92
3.4.1	Архитектура	93
3.4.2	Пакетная нормализация	99
3.4.3	Архитектура ResNet50.....	100
	Резюме	104

4	Основы процесса тренировки	106
4.1	Прямая подача и обратное распространение	107
4.1.1	Подача данных.....	108
4.1.2	Обратное распространение	108
4.2	Разбивка набора данных	110
4.2.1	Тренировочный и тестовый наборы	111
4.2.2	Кодирование с одним активным состоянием.....	113
4.3	Нормализация данных	116
4.3.1	Нормализация	116
4.3.2	Стандартизация	118
4.4	Валидация и переподгонка.....	119
4.4.1	Валидация.....	119
4.4.2	Слежение за потерей	123
4.4.3	Погружение вглубь с помощью слоев	123
4.5	Схождение.....	125
4.6	Фиксация контрольных точек и ранняя остановка	128
4.6.1	Фиксация контрольной точки	128
4.6.2	Ранняя остановка	130
4.7	Гиперпараметры	131
4.7.1	Эпохи	132

4.7.2	Шаги	132
4.7.3	Размер пакета	134
4.7.4	Скорость усвоения	135
4.8	Инвариантность	138
4.8.1	Трансляционная инвариантность	140
4.8.2	Масштабная инвариантность	147
4.8.3	ImageDataGenerator модуля TF.Keras	148
4.9	Сырые (дисковые) наборы данных	150
4.9.1	Каталожная структура	151
4.9.2	Файл CSV	153
4.9.3	Файл JSON	154
4.9.4	Чтение изображений	154
4.9.5	Изменение размера	157
4.10	Сохранение/восстановление модели	160
4.10.1	Сохранение	160
4.10.2	Восстановление	160
	Резюме	161

Часть II **БАЗОВЫЙ ШАБЛОН КОНСТРУИРОВАНИЯ**163

5	Шаблон процедурного конструирования	165
5.1	Базовая нейросетевая архитектура	167
5.2	Стержневой компонент	169
5.2.1	VGG	169
5.2.2	ResNet	171
5.2.3	ResNeXt	176
5.2.4	Xception	178
5.3	Предстержень	179
5.4	Ученический компонент	180
5.4.1	ResNet	182
5.4.2	DenseNet	185
5.5	Задачный компонент	187
5.5.1	ResNet	188
5.5.2	Многослойный выход	189
5.5.3	SqueezeNet	192
5.6	За пределами компьютерного зрения: обработка естественного языка	194
5.6.1	Понимание естественного языка	194
5.6.2	Трансформерная архитектура	196
	Резюме	197

6	Широкие сверточные нейронные сети	199
6.1	Inception v1	201
6.1.1	Нативный модуль Inception	201
6.1.2	Модуль Inception v1	204
6.1.3	Стержень	207
6.1.4	Ученик	207

6.1.5	Вспомогательные классификаторы	208
6.1.6	Классификатор	210
6.2	Inception v2: разложение сверток	211
6.3	Inception v3: модернизация архитектуры	214
6.3.1	Группы и блоки архитектуры Inception	215
6.3.2	Нормальная свертка	219
6.3.3	Пространственно разделяемая свертка	220
6.3.4	Модернизация и имплементация стержня	220
6.3.5	Вспомогательный классификатор	222
6.4	ResNeXt: широкие остаточные нейронные сети	223
6.4.1	Блок ResNeXt	224
6.4.2	Архитектура ResNeXt	227
6.5	Широкая остаточная сеть	228
6.5.1	Архитектура WRN-50-2	228
6.5.2	Широкий остаточный блок	229
6.6	За пределами компьютерного зрения: структурированные данные	230
	Резюме	233

7 Альтернативные шаблоны связности

7.1	DenseNet: плотносвязанная сверточная нейронная сеть	237
7.1.1	Плотная группа	237
7.1.2	Плотный блок	240
7.1.3	Макроархитектура DenseNet	243
7.1.4	Плотный переходный блок	244
7.2	Xception: экстремальное начало	245
7.2.1	Архитектура Xception	247
7.2.2	Входной поток Xception	249
7.2.3	Срединный поток модели Xception	252
7.2.4	Выходной поток архитектуры Xception	253
7.2.5	Свертка, разделяемая по глубине	256
7.2.6	Свертка вглубь	256
7.2.7	Точечная свертка	256
7.3	SE-Net: сдавливание и возбуждение	258
7.3.1	Архитектура SE-Net	258
7.3.2	Группа и блок архитектуры SE-Net	259
7.3.3	Связь SE	261
	Резюме	262

8 Мобильные сверточные нейронные сети

8.1	MobileNet v1	264
8.1.1	Архитектура	265
8.1.2	Множитель ширины	266
8.1.3	Множитель разрешающей способности	267
8.1.4	Стержень	268
8.1.5	Ученик	271
8.1.6	Классификатор	273
8.2	MobileNet v2	274
8.2.1	Архитектура	275

8.2.2	Стержень	276
8.2.3	Ученик	277
8.2.4	Классификатор	281
8.3	SqueezeNet	282
8.3.1	Архитектура	283
8.3.2	Стержень	284
8.3.3	Ученик	285
8.3.4	Классификатор	288
8.3.5	Обходные соединения	290
8.4	ShuffleNet v1	294
8.4.1	Архитектура	295
8.4.2	Стержень	295
8.4.3	Ученик	296
8.5	Развертывание	304
8.5.1	Квантизация	304
8.5.2	Конверсия и предсказание с TF Lite	306
	Резюме	308

9 Автокодировщики

9.1	Глубокие нейросетевые автокодировщики	310
9.1.1	Архитектура автокодировщика	310
9.1.2	Кодировщик	312
9.1.3	Декодировщик	313
9.1.4	Тренировка	313
9.2	Сверточные автокодировщики	315
9.2.1	Архитектура	316
9.2.2	Кодировщик	317
9.2.3	Декодировщик	318
9.3	Разреженные автокодировщики	320
9.4	Автокодировщики для устранения шума	321
9.5	Сверхразрешающая способность	322
9.5.1	Сверхразрешение на основе предтбора с повышенной частотой	323
9.5.2	Сверхразрешение на основе посттбора с повышенной частотой	326
9.6	Предлоговые задачи	330
9.7	За пределами компьютерного зрения: последовательность к последовательности	333
	Резюме	334

Часть III РАБОТА С КОНВЕЙЕРАМИ

10 Гиперпараметрическая настройка

10.1	Инициализация весов	340
10.1.1	Распределения весов	341
10.1.2	Лотерейная гипотеза	342
10.1.3	Разминка (численная стабилизация)	344
10.2	Основы гиперпараметрического поиска	347

10.2.1	Ручной метод гиперпараметрического поиска	349
10.2.2	Решеточный поиск	350
10.2.3	Случайный поиск	351
10.2.4	Инструмент настройки KerasTuner	354
10.3	Планировщик скорости усвоения	357
10.3.1	Параметр затухания в Keras	357
10.3.2	Планировщик скорости усвоения в Keras	358
10.3.3	Рампа.....	359
10.3.4	Постоянный шаг	360
10.3.5	Косинусное закаливание.....	361
10.4	Регуляризация.....	364
10.4.1	Регуляризация весов	364
10.4.2	Сглаживание меток	365
10.5	За пределами компьютерного зрения	367
	Резюме	368

11	Перенос обучения.....	369
11.1	Предварительно построенные модели TF.Keras	371
11.1.1	Базовая модель	372
11.1.2	Преднатренированные на ImageNet модели для предсказаний.....	374
11.1.3	Новый классификатор	375
11.2	Предварительно построенные модели TF Hub	380
11.2.1	Применение преднатренированных моделей TF Hub	381
11.2.2	Новый классификатор	383
11.3	Перенос обучения между предметными областями	385
11.3.1	Похожие задачи	385
11.3.2	Несовпадающие задачи	387
11.3.3	Предметно-специфичные веса.....	390
11.3.4	Инициализация предметно-переносимыми весами	392
11.3.5	Отрицательный перенос	394
11.4	За пределами компьютерного зрения	394
	Резюме	395

12	Распределения данных.....	396
12.1	Типы распределений.....	397
12.1.1	Популяционное распределение	398
12.1.2	Выборочное распределение	399
12.1.3	Подпопуляционное распределение	401
12.2	Вне распространения	402
12.2.1	Курируемый набор данных MNIST	402
12.2.2	Настройка среды	403
12.2.3	Серьезное испытание («дикой природой»).....	404
12.2.4	Тренировка в качестве глубокой нейросети.....	405
12.2.5	Тренировка в качестве сверточной нейросети.....	412
12.2.6	Обогащение изображений	415
12.2.7	Заключительный тест	418
	Резюме	419

13	Конвейер данных	420
13.1	Форматы и хранение данных	422
13.1.1	Форматы сжатых и сырых изображений	423
13.1.2	Формат HDF5	427
13.1.3	Формат DICOM	432
13.1.4	Формат TFRecord	434
13.2	Подача данных	440
13.2.1	NumPy	441
13.2.2	TFRecord	443
13.3	Предобработка данных	446
13.3.1	Предобработка с помощью предстержня	446
13.3.2	Предобработка с помощью расширенного TensorFlow (TF Extended)	455
13.4	Обогащение данных	460
13.4.1	Инвариантность	461
13.4.2	Обогащение с помощью tf.data	464
13.4.3	Предстержень	465
	Резюме	466
14	Конвейер тренировки и развертывания	467
14.1	Подача данных в модель	469
14.1.1	Подача данных в модель с помощью tf.data.Dataset	474
14.1.2	Распределенная подача с помощью tf.Strategy	478
14.1.3	Подача данных в модель с помощью TFX	480
14.2	Планировщики тренировки	488
14.2.1	Версионирование конвейера	490
14.2.2	Метаданные	492
14.2.3	История	494
14.3	Оценивание моделей	496
14.3.1	Кандидатная модель против одобренной модели	496
14.3.2	Оценивание в TFX	501
14.4	Обслуживание предсказательных запросов	504
14.4.1	Обслуживание по требованию (в реальном времени)	505
14.4.2	Пакетное предсказание	508
14.4.3	Конвейерные компоненты TFX для развертывания	510
14.4.4	A/B-тестирование	512
14.4.5	Балансировка нагрузки	514
14.4.6	Непрерывное оценивание	516
14.5	Эволюция в конструировании производственных конвейеров	517
14.5.1	Машинное обучение в качестве конвейера	518
14.5.2	Машинное обучение как производственный процесс CI/CD	519
14.5.3	Консолидация моделей в производстве	519
	Резюме	521
	Предметный указатель	522

Предисловие

Одна из моих обязанностей в качестве сотрудника Google состоит в том, чтобы обучать инженеров-программистов приемам применения машинного обучения. У меня уже был опыт создания онлайн-учебных занятий, встреч, презентаций на конференциях, рабочих семинаров и курсовых работ для частных школ программирования и аспирантур университетов, но я всегда ищу новые способы эффективного преподавания.

До Google я в течение 20 лет проработал в японской информационно-технологической индустрии в качестве главного научного сотрудника – и все время без глубокого обучения. Почти все, что я вижу сегодня, мы делали в инновационных лабораториях 15 лет назад; разница лишь в том, что нам нужен был коллектив, полный ученых, и огромный бюджет. Невероятно, как все так быстро поменялось в результате повсеместного внедрения технологии глубокого обучения.

Еще в конце 2000-х годов я работал с небольшими структурированными наборами геопространственных данных из национальных и международных источников, разбросанных по всему миру. Коллеги называли меня исследователем данных, но никто не знал, что это такое на самом деле. Затем появились большие данные, которые проявили мою неосведомленность об инструментах и каркасах больших данных, и я неожиданно перестал быть исследователем данных. Вот незадача. Мне пришлось поднапрячься и изучить инструменты и концепции, лежащие в основе больших данных, и я снова стал исследователем данных.

И вот появилось машинное обучение на больших наборах данных, такое как линейная/логистическая регрессия и анализ CART, а я не использовал статистику со времен аспирантуры десятилетней давности, и я снова перестал быть исследователем данных. Вот дела! Мне пришлось поднапрячься и выучить статистику заново, и я снова стал исследователем данных. Затем пришло глубокое обучение, а я не знал теории и основ нейронных сетей, и я внезапно перестал быть исследователем данных. Что опять? Но я снова поднапрягся и изучил теорию и другие основы глубокого обучения. И опять-таки, теперь я – снова исследователь данных.

Признательности

Хотел бы поблагодарить всех сотрудников издательства Manning, которые помогли на протяжении всего этого процесса. Франческу Лефковиц, редактора по разработке; Дейдруе Хиам, редактора проектов; Шарон Уилки, редактора-копирайтера; Кери Хейлз, корректора; и Александра Драгошавлевича, редактора-рецензента.

Всем рецензентам: Ариэль Гамино, Арне Питер Раульф, Барри Сигел, Брайан Р. Гейнс, Кристофер Маршалл, Кертис Бейтс, Эрос Педрини, Хильде Ван Гизель, Ишан Хурана, Джен Ли, Картикеяраджан Раджендран, Майкл Кареев, Мухаммад Сохаиб Ариф, Ник Васкес, Нинослав Черкез, Оливер Кортен, Пиюш Мехта, Ричард Тобиас, Ромит Синг-хай, Саяк Пол, Серджио Говони, Симона Сгуацца, Удендран Мудалияр, Вишвеш Рави Шримали и Витон Витанис, – ваши предложения помогли сделать эту книгу лучше.

Всем сотрудникам Google Cloud AI, которые поделились своими личными знаниями и сведениями в области клиентских предпочтений, – ваши идеи помогли книге охватить более широкую аудиторию.

Об этой книге

Кому следует прочитать эту книгу

Добро пожаловать в мое последнее начинание – книгу «Шаблоны и практика глубокого обучения». Эта книга предназначена для инженеров-программистов, инженеров машинного обучения, а также младших, средних и старших специалистов-исследователей данных. Хотя вы, возможно, посчитаете, что начальные главы будут полезны для последней группы, мой уникальный подход, скорее всего, даст вам дополнительную информацию и поможет освежить знания. Книга построена так, чтобы каждый читатель достиг точки «зажигания» и смог продвигаться вперед к глубокому обучению самостоятельно.

Я преподаю шаблоны конструирования и образцы практики главным образом в контексте компьютерного зрения, так как именно здесь шаблоны конструирования появились для глубокого обучения впервые. Разработки в области понимания естественного языка и моделей структурированных данных отставали и по-прежнему были сосредоточены на классических подходах. Но по мере того, как они догоняли, эти области вырабатывали свои собственные шаблоны конструирования для решения задач глубокого обучения, и я излагаю эти шаблоны и образцы практики на протяжении всей книги.

Несмотря на то что я демонстрирую исходный код моделей компьютерного зрения, мое внимание сосредоточено на концепциях, лежащих в основе подходов и инноваций: тому, как они устроены и почему они устроены таким образом. Указанные опорные концепции применимы к обработке естественного языка, структурированным данным, обработке сигналов и другим областям, и, резюмируя, вы должны быть в состоянии адаптировать эти концепции, методы и образцы практики к задачам в вашей предметной области. Многие модели и методы, которые я обсуждаю, не зависят от предметной области, и на протяжении всей книги, где это уместно, я также обсуждаю ключевые инновации в областях обработки естественного языка, понимания естественного языка и структурированных данных.

Если говорить об общей подготовке, то вы должны знать, по крайней мере, основы Python. Все в порядке, если вы все еще пытаетесь разобраться в том, что такое включение в список или генератор, или если у вас все еще есть некоторая путаница в отношении странного среза многомерного массива и того, какие объекты являются мутируемыми и немутуруемыми в куче. Для этой книги данного уровня будет достаточно.

Какой должна быть подготовка тех инженеров-программистов, которые хотят стать инженерами машинного обучения? Инженер машинного обучения (MLE) – это инженер-прикладник. Вам не требуется знать статистику (реально не нужно!), и вам не требуется знать теорию вычислений. Если вы заснули в колледже на уроке математики на теме производной, то это нормально, и если кто-то попросит вас выполнить матричное умножение, не стесняйтесь спрашивать, зачем оно нужно.

Ваша задача состоит в том, чтобы изучить «кнопки и рычаги» вычислительного каркаса и применять свои навыки и опыт для выработки решений реально существующих задач. Вот в чем я собираюсь вам помочь, и вот в чем суть шаблонов конструирования с использованием модуля TF.Keras.

Эта книга предназначена для инженеров машинного обучения и исследователей данных на сопоставимых уровнях. Тем же, кто следует по пути анализа данных, я рекомендую изучить дополнительные материалы, связанные со статистикой.

Прежде чем мы начнем, я хочу объяснить, как вы будете учиться, поэтому в данном первом разделе больше рассказывается о моей философии и подходе к преподаванию. Затем мы рассмотрим некоторые основополагающие материалы, включая терминологию, переход от классического или семантического ИИ к узкому или статистическому ИИ, а также проведем обзор основных шагов машинного обучения. Наконец, мы подробно остановимся на том, чему посвящена книга: на современном подходе к машинному обучению, основанному на *консолидации моделей*.

Я не использую традиционный западный подход: заучивание наизусть, повторение, повторение, проверка правильности ответов и затем продвижение вертикально вверх. Помимо моего мнения о том, что такой подход к преподаванию менее эффективен, я считаю, что он непреднамеренно дискриминирует учащихся.

Вместо этого я имел возможность преподавать инженерное дело и естественные науки в различных культурах и методиках преподавания и разработал уникальный стиль преподавания, с привлечением того, что я называю *боковым подходом*: я начинаю с ключевых понятий, а затем продвигаюсь по спирали, используя то, что я называю *абстракцией*. Когда начнут задаваться вопросы, я постепенно перехожу к указыванию другим студентам на их мысли по поводу ответов на эти вопросы, а потом размышляю над их мыслями. Я не провожу контрольные работы, в которых студенты пытаются получить 100 %. Вместо этого я даю задания, которые каждый студент провалит. Я по-

зволюю студентам биться над задачей изо всех сил, и при этом они начинают открывать для себя опорные принципы того, что им нужно усвоить. Например, я могу дать задание натренировать стандартную модель ResNet50 с использованием набора данных CIFAR-10, отметив, что авторы соответствующих статей по ResNet достигли на CIFAR-10 точности 97 %. Каждый студент провалит решение, модель не сойдется, они не наберут более 70 % и так далее.

Затем я собираю студентов в группы, чтобы решать задачи вместе. Совещаясь друг с другом, они учатся делать совместные обобщения. И прежде чем они достаточно созреют, я совершаю прыжок, в котором ставлю перед студентами еще одну трудноразрешимую задачу, – и процесс начинается снова. Я никогда не даю студентам возможности заучивать наизусть.

Используя свой пример, я могу разместить на доске четыре возможных решения, например: 1) обогащение изображений, 2) еще больше регуляризации, 3) еще больше гиперпараметрического поиска, 4) отложить снижение размера изображения глубоко внутрь нейронной сети (это правильный ответ). Далее в середине я останавливаю студентов и прошу каждую группу указать опробованное ими решение и то, что они усвоили к тому моменту. Затем я объясняю причины правильности/неправильности каждого решения, а потом снова меняю задачу.

По мере того как студенты переходят на более продвинутые уровни, я переключаюсь с роли учителя на то, что я называю ролью магистранта, и участвую в обучении. Студенты учат меня и друг друга так же, как я учу их. Я наблюдаю за каждым студентом и ищу то, что я называю *зажиганием*, – этап, когда студент начнет саморазвиваться как ученик, то есть когда он учится постоянно. В своем методе преподавания я замечаю, что весь класс собирается вместе и ни один ученик не остается позади.

Время от времени на одно из моих занятий приходил администратор школы программирования. Он слышал доносящуюся от студентов болтовню и хотел понаблюдать за тем, как это работает. Разумеется, администраторы испытывают потребность в том, чтобы всему давать название. В одной частной школе программирования администратор описал мою методику как «каждый становится учеником». Студенты учатся у учителя, учитель учится у студентов, и студенты учатся у студентов. Администратор назвал ее «Давайте учиться вместе».

У меня же для моей методики преподавания есть собственное название, а именно «Я верю в себя». Я часто говорю своим ученикам: как можно верить в меня («учителя»), если вы прежде всего не верите в себя?

Как эта книга организована: дорожная карта

Эта книга состоит из трех частей: основы, общие шаблоны конструирования и шаблоны конструирования для решения задач тренировки и развертывания в производстве.

Часть I «Основы глубокого обучения» предоставляет читателям обновленную информацию о глубоком обучении, которая включает введение в сверточные нейронные сети, а также обсуждение концепций и терминологии, которые являются сегодня магистральными для всех областей – компьютерного зрения, обработки естественного языка и структурированных данных.

Шаблоны конструирования моделей представлены в части II «Базовые шаблоны конструирования». В главах 5–7 я ввожу современные шаблоны конструирования и способы их применения ко многим современным и некогда передовым моделям глубокого обучения. Я расскажу о шаблоне процедурного реиспользования, который был преобладающим подходом для моделей, которые конструировались вручную. Я излагаю подходы к конструированию, усовершенствования и плюсы/минусы крупных моделей, обнаруженных исследователями для движения послойно вглубь (глава 5), движения послойно вширь (глава 6), и применению альтернативных или готовых («прямо из коробки») шаблонов связности (глава 7).

В главе 5 рассматривается шаблон процедурного конструирования для сверточных нейронных сетей, а также разработка остаточных блоков с отождествляющими связями с вниманием в трансформерах для понимания естественного языка.

В главе 6 подробно рассказывается о шаблоне процедурного конструирования для сверточных нейронных сетей и о том, как исследователи развели движение послойно в ширину в качестве альтернативы движению в глубину. Я показываю, каким образом такой подход, как ResNeXt, привел к достижению сравнимой точности в сопоставлении с глубокими слоями с меньшей подверженностью забыванию и исчезающим градиентам. Я также проведу разведывательный анализ степени релевантности широких сверточных нейронных сетей для разработок в широких и глубоких моделях TabNet для структурированных данных.

В главе 7 рассматриваются шаблоны конструирования моделей. Указанные шаблоны разведывают другие альтернативные соединения между слоями, чтобы двигаться послойно вглубь либо вширь с целью повышения точности, сокращения числа параметров и увеличения прироста информации в промежуточном латентном пространстве внутри модели.

В главе 8 инспектируются уникальные конструктивные соображения и особые ограничения для мобильных сверточных нейронных сетей. Из-за ограничений этих устройств по памяти необходимо учитывать компромиссы между размером и точностью. Я расскажу о прогрессе в этих компромиссах, плюсах/минусах и о том, как конструкции мобильных сетей отличаются от их крупномодельных виазави, чтобы учесть эти компромиссы.

В главе 9 представлены автокодировщики для неконтролируемого обучения. Практическая применимость автокодировщиков в качестве автономных моделей очень узка. Но сделанные автокодировщи-

ками открытия способствовали прогрессу в предтренировке моделей. Такие модели лучше обобщают на обслуживание запросов вне распределения, то есть на предсказательные запросы к модели, развернутой в производственной среде, которые имеют иное распределение, чем данные, на которых модель была натренирована. Я также разведую сопоставимость автокодировщиков с векторными вложениями в отрасли понимания естественного языка.

Все модели во второй части этой книги внесли эпохальный вклад в исследования и разработки в области глубокого обучения и продолжают использоваться сегодня, либо их вклад был включен в современные модели.

В части III «Работа с конвейерами» рассматриваются шаблоны конструирования и образцы практики для производственных конвейеров. В главе 10 мы рассмотрим гиперпараметрическую настройку, как ручную, так и автоматическую. Я изложу конструктивные решения, плюсы/минусы и лучшие практические приемы определения пространства поиска и шаблонов поиска в нем.

В главе 11 обсуждается тема переноса обучения (трансферного обучения) и вводятся концепции и методы манипулирования переносом весов и настройки под аналогичные и отдаленные задачи. Я также рассматриваю приложение по переносу предметных знаний с целью реиспользования весов во время предтренировки; данное приложение предназначено для моделей, которые тренируются полностью с нуля.

В главах с 12 по 14 выполняется высокоуровневый обзор производственных конвейеров. В главах 12 и 13 мы погрузимся в эту тему со стороны данных. Глава 12, в которой рассказывается о распределении данных, является единственной, в которой статистика излагается подробно. С 2017 года, когда можно было ожидать, что специалист будет обладать знаниями в области статистики на уровне доктора философии, многое изменилось. Сегодня многое из того скрыто или же автоматизировано в каркасах глубокого обучения, таких как TensorFlow. Понимание распределения данных и пространства поиска остается одной из преобладающих областей ожидаемых знаний из области статистики, и оно может существенно влиять на стоимость тренировки и способность модели обобщать после ее развертывания в производстве.

Наконец, в главах 13 и 14 мы переходим со стороны данных на сторону развертывания. Я рассказываю о концепциях и лучших образцах практики конструирования со стороны данных, а затем со стороны тренировки производственного конвейера.

Об исходном коде

Эта книга содержит массу примеров исходного кода как в пронумерованных листингах, так и во вставках, встроенных в обычный текст. В обоих случаях исходный код отформатирован шрифтом фиксированной

ширины, чтобы отделять его от обычного текста. Иногда исходный код также выделяется **жирным шрифтом**, чтобы выделять исходный код, который изменился по сравнению с предыдущими шагами в главе, например когда в существующую строку исходного кода добавляется новая функция.

Во многих случаях исходный код был переформатирован; мы добавили разрывы строк и переработали отступы, чтобы уложиться в доступное пространство книжной страницы. Кроме того, комментарии в исходном коде часто из листингов удалялись, когда исходный код описывался в тексте. Многочисленные листинги сопровождаются аннотациями исходного кода, выделяя важные концепции.

Все приводимые в книге примеры исходного кода написаны на Python и являются рабочими; правда, в них могут отсутствовать инструкции импорта. Во многих случаях образцы исходного кода являются частью более крупного компонента, такого как модель. В подобных случаях весь исходный код доступен в моем публичном репозитории для связей с разработчиками Google Cloud AI на GitHub (<https://github.com/GoogleCloudPlatform/keras-idiomatic-programmer/tree/master/zoo>).

Другие онлайн-ресурсы

Я использую вычислительный каркас TensorFlow 2.x, в который включен API моделей Keras. Я думаю, что сочетание этих двух факторов является фантастическим средством для образования, выходящим за рамки их производственной ценности.

Материал книги является мультимодальным. В дополнение к книге и полным образцам исходного кода в репозитории на моем YouTube-канале для связей с разработчиками Google Cloud AI (www.youtube.com/канал/uc8ov0vkzhttp8_puwedzlbjg) есть слайды презентаций, семинары, лабораторные работы и предварительно записанные лекции по каждой главе.

Отзывы и пожелания

Мы всегда рады отзывам наших читателей. Расскажите нам, что вы думаете об этой книге, – что понравилось или, может быть, не понравилось. Отзывы важны для нас, чтобы выпускать книги, которые будут для вас максимально полезны.

Вы можете написать отзыв на нашем сайте www.dmkpress.com, зайдя на страницу книги и оставив комментарий в разделе «Отзывы и рецензии». Также можно послать письмо главному редактору по адресу dmkpress@gmail.com; при этом укажите название книги в теме письма.

Если вы являетесь экспертом в какой-либо области и заинтересованы в написании новой книги, заполните форму на нашем сайте по

адресу http://dmkpress.com/authors/publish_book/ или напишите в издательство по адресу dmkpress@gmail.com.

Список опечаток

Хотя мы приняли все возможные меры для того, чтобы обеспечить высокое качество наших текстов, ошибки все равно случаются. Если вы найдете ошибку в одной из наших книг, мы будем очень благодарны, если вы сообщите о ней главному редактору по адресу dmkpress@gmail.com. Сделав это, вы избавите других читателей от недопонимания и поможете нам улучшить последующие издания этой книги.

Нарушение авторских прав

Пиратство в интернете по-прежнему остается насущной проблемой. Издательства «ДМК Пресс» и Manning Publications очень серьезно относятся к вопросам защиты авторских прав и лицензирования. Если вы столкнетесь в интернете с незаконной публикацией какой-либо из наших книг, пожалуйста, пришлите нам ссылку на интернет-ресурс, чтобы мы могли применить санкции.

Ссылку на подозрительные материалы можно прислать по адресу электронной почты dmkpress@gmail.com.

Мы высоко ценим любую помощь по защите наших авторов, благодаря которой мы можем предоставлять вам качественные материалы.

Об авторе

Я твердо верю, что мой жизненный опыт делает меня одним из самых идеальных людей для преподавания концепций глубокого обучения. Когда эта книга выйдет из печати в первый раз, мне будет почти 60 лет. Я обладаю богатыми знаниями и опытом, которые сегодня соответствуют ожиданиям сотрудников. В 1987 году я получил ученую степень в области искусственного интеллекта. Я специализировался на обработке естественного языка. Когда я закончил колледж, то думал, что буду писать говорящие книги. Как оказалось, это было время зимы искусственного интеллекта.

В начале своей карьеры я выбрал другие направления. Прежде всего я стал экспертом в области государственной безопасности для мейнфреймов. По мере того как я набирался все больше опыта в конструировании и программировании ядер операционных систем, я стал разработчиком ядра для UNIX, будучи одним из авторов современного тяжеловесного ядра UNIX. В те же годы я участвовал в популяризации свободно распространяемого ПО «shareware» (еще до раскрытия исходного кода) и был основателем WINNIX, условно-бесплатной программы, которая конкурировала с коммерческим инструментарием MKS для исполнения оболочки UNIX и команд в среде DOS.

Впоследствии я разработал низкоуровневый инструментарий объектного кода. В начале 1990-х я стал экспертом как в области вычислений на защищенном уровне, так и в области компиляторов/ассемблеров для массово-параллельных вычислений. Я разработал инструмент MetaC, который обеспечивал инструментальную поддержку ядер операционных систем как традиционных операционных систем, так и высокозащищенных и массово-параллельных компьютеров.

В конце 1990-х годов я сменил карьеру и стал научным сотрудником японской корпорации Sharp. Через пару лет я стал главным научным сотрудником этой компании в Северной Америке. За 20-летний период Sharp подала более 200 заявок на патенты в США на мои исследования, из которых 115 были удовлетворены. Мои патенты охватывали области солнечной энергетики, телеконференций, ви-

зуализации, цифровых интерактивных вывесок и автономных транспортных средств. Кроме того, в 2014–2015 годах я был признан ведущим мировым экспертом по открытым данным и онтологиям данных и основал организацию *opengeocode*.

В марте 2017 года, по настоянию моего друга, я решил посмотреть, «что это за диковинка такая, которую называют глубоким обучением». Для меня это было естественно. У меня был большой опыт работы с данными, я работал специалистом и исследователем по обработке изображений, имел степень магистра искусственного интеллекта, работал над автономными транспортными средствами – все это, казалось, укладывалось в одну линию. И стало быть, я совершил прыжок.

Летом 2018 года Google обратилась ко мне с просьбой стать сотрудником Google Cloud AI. Я принял должность в октябре того же года. Это был и остается великолепный опыт работы в Google. Сегодня я работаю с огромным числом экспертов в области искусственного интеллекта как в Google, так и с корпоративными клиентами Google, обучая, наставляя, консультируя и решая задачи по внедрению глубокого обучения в больших производственных масштабах.

Об иллюстрации на обложке

Рисунок на обложке книги «Шаблоны и практика глубокого обучения» озаглавлен «Индиец», или человек родом из Индии. Иллюстрация взята из коллекции костюмов из разных стран Жака Грассе де Сен-Совера (1757–1810) под названием «Костюмы разных стран», опубликованной во Франции в 1784 году. Каждая иллюстрация тщательно прорисована и оформлена вручную. Богатое разнообразие коллекции Грассе де Сен-Совера живо напоминает нам о том, насколько культурно обособленными были города и регионы мира всего 200 лет назад. Изолированные друг от друга люди говорили на разных диалектах и языках. На улицах городов или в деревнях было легко просто по их одежде определить, где они живут и каково их ремесло или положение в жизни.

С тех пор наша манера одеваться изменилась, и региональное разнообразие, столь богатое в то время, исчезло. В настоящее время трудно отличить жителей разных континентов, не говоря уже о разных городах, регионах или странах. Возможно, мы променяли культурное разнообразие на более разнообразную личную жизнь – безусловно, на более разнообразную и быстро развивающуюся технологическую жизнь.

Сегодня, когда трудно отличить одну компьютерную книгу от другой, издательство Manning демонстрирует изобретательность и инициативу компьютерного бизнеса, предлагая обложки книг, основанные на богатом разнообразии региональной жизни двухвековой давности, оживленной картинами Грассе де Сен-Совера.

Часть I

Основы машинного обучения

В этой части вы изучите основы, необходимые для того, чтобы приступить к строительству моделей глубокого обучения. Мы начинаем с базовых принципов и шагов глубоких нейронных сетей (deep neural networks, аббр. DNN), с многочисленных диаграмм, иллюстрирующих эти шаги, а также с фрагментов исходного кода, которые имплементируют эти шаги. Я опишу каждый шаг, а затем расскажу об исходном коде. Далее мы рассмотрим принципы и шаги работы сверточных нейронных сетей (convolutional neural networks, аббр. CNN). Я проведу вас по эпохальным шаблонам конструирования. Указанные шаблоны лежали в основе ранних передовых сетей VGG и ResNet. Вы научитесь кодировать каждую из этих модельных архитектур, имея в распоряжении полный исходный код, который находится в общедоступном репозитории книги на GitHub.

Что будет дальше, после того как вы начнете кодировать сверточные нейросети? Вы будете их тренировать. Мы завершаем эту часть усвоением принципиальных знаний, касающихся тренировки сверточных нейросетевых моделей.

Конструирование современного машинного обучения

Эта глава охватывает следующие ниже темы:

- эволюция от классического ИИ к новейшим подходам;
- применение шаблонов конструирования для глубокого обучения;
- знакомство с шаблоном конструирования, именуемым «процедурным реиспользованием», для моделирования нейронных сетей.

Последняя революция в области глубокого обучения, с внедрением подхода, который я назвал, работая в Google Cloud AI, *консолидацией моделей* (model amalgamation), происходит не на микро-, а на макро-уровне. При таком подходе модели разбиваются на составные единицы, коллективно использующие и адаптирующие компоненты с целью достижения разных целевых задач с одинаковыми первоначальными данными. Указанные компоненты взаимосвязаны в различных шаблонах связности, в которых каждый компонент *усваивает* коммуникационные интерфейсы между моделями на основе конструкции, не нуждаясь в том, чтобы иметь приложение серверного типа (бэкенд).

В дополнение к этому консолидация моделей может использоваться для тренировки устройств интернета вещей (IoT) с целью обогащения данных, преобразуя датчики интернета вещей из статических в динамически обучающиеся устройства – данный технический прием получил название *сращивание моделей*. Консолидация предоставляет средства для внедрения ИИ в производство в масштабах и слож-

ности эксплуатации, невысказанных в 2017 году, когда только-только начиналось движение в сторону производства.

Подумайте, например, об операционной сложности визуальных данных об объектах недвижимости, связанной с различными аспектами рынка аренды, таких как цены, состояние объекта недвижимости и удобства. Используя подход в форме консолидаций моделей, можно создать конвейер анализа общей картины, который соединяет компоненты отдельных моделей, каждый из которых работает над одним из этих аспектов. В конце у вас будет система, которая автоматически учится определять состояние, удобства и общую привлекательность рынка с соответствующими и надлежащими расценками арендной платы.

Подход в форме консолидаций моделей побуждает инженеров рассматривать модели как шаблоны или заготовки конструктивных решений, которые можно приспосабливать для создания индивидуальных компонентов. Поэтому если вы надеетесь использовать этот подход, то вам нужно будет понять конструкции ключевых моделей и систем, разработанных другими инженерами для решения задач, подобных тем, с которыми столкнетесь вы.

Цель этой книги состоит в том, чтобы помочь вам в этом глубоком понимании, познакомив вас с шаблонами конструирования эпохальных моделей глубокого обучения, а также с конструкцией или системной архитектурой, которая сводит эти компоненты вместе для разработки, тренировки, развертывания и обслуживания более крупных систем глубокого обучения. Даже если вы никогда не работали с огромными консолидациями, применяемыми на производственных предприятиях, свободное владение опорными конструкциями этих моделей и архитектур улучшит разработку любой создаваемой вами системы глубокого обучения.

1.1 Курс на адаптируемость

Поскольку эта книга предназначена для не совсем опытных инженеров глубокого обучения и исследователей данных, часть I начинается с конструкций базовых глубоких нейронных сетей (DNN), сверточных нейронных сетей (CNN) и остаточных нейронных сетей (ResNet). В части I также рассматривается архитектура простых конвейеров тренировки. Об этих сетях и архитектурах и только о них в свое время были написаны целые книги, поэтому здесь вы получите больше напоминаний о том, как они работают, с акцентом на шаблонах и конструктивных принципах. Суть тут в том, чтобы изложить конструкцию базовых компонентов глубокого обучения, куда будут вписываться все модели, которые вы увидите в части II.

Тем не менее если вы разбираетесь в основах хорошо, то вы можете перейти непосредственно к части II, в которой рассматриваются модели, сыгравшие эпохальную роль в развитии глубокого обучения.

Мой подход заключается в том, чтобы давать информацию о конструкции каждой модели в объеме, достаточном для того, чтобы у вас была возможность с ними поиграть и обдумать решения задач искусственного интеллекта, с которыми вы, возможно, столкнетесь. Модели представлены более или менее хронологически, поэтому часть II также служит своего рода историей глубокого обучения с акцентом на эволюцию от одной модели к другой.

Далее, если производство на предприятиях переходит к автоматическому усвоению и развитию моделей, то вы можете задаться вопросом о ценности проведения ревизии этих сконструированных вручную, некогда передовых (state-of-the-art, аббр. SOTA) моделей. И тем не менее многие из этих моделей по-прежнему используются в качестве стоковых моделей, в особенности для переноса обучения (трансферного обучения). Некоторые же вообще не попали в производство, но сыграли неоценимую роль в открытиях, которые продолжают использоваться сегодня.

Разработка моделей для производства по-прежнему представляет собой комбинацию автоматического усвоения и ручного обучения, что часто имеет решающее значение для собственных нужд или достижений. Но конструирование вручную не означает, что нужно начинать с нуля; как правило, вы начинаете со стандартной модели и вносите изменения и корректировки. Для того чтобы делать это эффективно, вам нужно разбираться в том, как модель работает и почему она работает таким образом, понимать концепции, лежащие в основе ее конструкции, а также плюсы и минусы альтернативных строительных блоков, которые вы будете узнавать из других передовых моделей.

Заключительная часть книги посвящена глубокому погружению в шаблоны конструирования для тренировки и развертывания в производстве. Хотя не все читатели будут развертывать интересные меня системы уровня производственного предприятия, я чувствую, что эта информация является актуальной для всех. Знакомство со многими типами и размерами систем, решающих самые разные производственные задачи, обязательно вам поможет, когда решение задачи потребует от вас нестандартного мышления. Чем больше вы знаете об опорных концепциях и конструкциях, тем умелее и способнее к адаптации вы становитесь.

Эта способность к адаптации, пожалуй, является самым ценным выводом из данной книги. Производство предусматривает огромное число движущихся частей и бесконечный поток «разводных гаечных ключей», бросаемых в смесь. Если инженеры или исследователи данных просто заучивают наизусть наборы воспроизводимых шагов в вычислительном каркасе, то как они будут справляться с разнообразием производственных задач, с которыми они будут сталкиваться, и увиливать от бросаемых в них разводных ключей? Работодатели ищут большего, чем просто навыки и опыт; они хотят знать, насколько вы технически адаптивны.

Вообразите себя на собеседовании: вы набираете высокие баллы по навыкам и опыту работы и справляетесь с производственной задачей кодирования машинного обучения. Затем рекрутеры бросают вам разводной ключ, неожиданную или необычную задачу. Они делают это, чтобы понаблюдать за тем, как вы обдумываете задачу, какие концепции вы применяете и обосновываете их, как вы оцениваете плюсы и минусы различных решений и каково ваше умение выполнять отладку. Это и есть способность к адаптации. И это то, что, я надеюсь, разработчики глубокого обучения и исследователи данных извлекут из данной книги.

1.1.1 Компьютерное зрение задает тон

Все эти концепции я преподаю в первую очередь в контексте компьютерного зрения, потому что шаблоны конструирования впервые появились именно в компьютерном зрении. Но они применимы и к обработке естественного языка (NLP), структурированным данным, обработке сигналов и другим областям. Если откатить время назад в период до 2012 года, то во всех областях машинного обучения использовались главным образом классические методы, основанные на статистике.

Различные академические исследователи, такие как Фей-Фей Лю (Fei-Fei Liu) из Стэнфордского университета и Джеффри Хинтон (Geoffrey Hinton) из Университета Торонто, стали пионерами в применении нейронных сетей к компьютерному зрению. Лю вместе со своими учениками собрала набор данных по компьютерному зрению, теперь известный как ImageNet, с целью продвижения исследований в области компьютерного зрения. В 2010 году ImageNet наряду с набором данных PASCAL стал основой для ежегодного конкурса ImageNet Large Scale Vision Recognition Challenge (ILSVRC). На ранних стадиях там использовались традиционные методы распознавания изображений/обработки сигналов.

Затем, в 2012 году, Алекс Крижевский (Alex Krizhevsky), также из Университета Торонто, продемонстрировал модель глубокого обучения AlexNet, используя слои свертки. Эта модель выиграла конкурс ILSVRC, и к тому же со значительным отрывом. Модель AlexNet, разработанная совместно с Хинтоном и Ильей Суцкевером (Ilya Sutskever), положила начало глубокому обучению. В своей статье «Классифицирование ImageNet с помощью глубоких сверточных нейронных сетей» (ImageNet Classification with Deep Convolutional Neural Networks, <http://mng.bz/1ApV>) они показали подход к конструированию нейронных сетей.

В 2013 году Мэтью Зейлер (Matthew Zeiler) и Роб Фергус (Rob Fergus) из Нью-Йоркского университета победили в конкурсе, доработав AlexNet до версии, которую они назвали ZFNet. И эта регулярность развития успеха друг друга продолжилась. Группа по визуальной геометрии в Оксфорде расширила конструктивные принципы AlexNet

и выиграла конкурс 2014 года. В 2015 году Каймин Хе (Kaiming He) и другие сотрудники Microsoft Research расширили конструктивные принципы AlexNet/VGG и выиграла конкурс, представив новые шаблоны конструирования. Их модель, ResNet, и их статья «Глубокое остаточное обучение для распознавания изображений» (Deep Residual Learning for Image Recognition, <https://arxiv.org/abs/1512.03385>) вызвали всплеск интереса к нащупыванию и разведыванию конструктивного пространства сверточных нейросетей.

1.1.2 *За пределами компьютерного зрения: обработка ЕЯ, понимание ЕЯ, структурированные данные*

В эти первые годы разработки принципов и шаблонов конструирования с использованием глубокого обучения для компьютерного зрения, разработки моделей понимания естественного языка (NLU) и структурированных данных отставали и продолжали концентрироваться на классических подходах. В них для ввода текста использовались классические каркасы машинного обучения, такие как Естественно-языковой инструментарий (NLTK), и для ввода структурированных данных – классические алгоритмы, основанные на деревьях решений, такие как случайный лес.

В сфере понимания естественного языка (NLU) с внедрением рекуррентных нейросетей (RNN) и слоев с долгой кратковременной памятью (LSTM) и вентильного рекуррентного блока (GRU) был достигнут прогресс. В 2017 году этот прогресс привел к скачку с введением трансформерного шаблона для естественного языка и публикацией соответствующей статьи «Внимание – это все, что вам нужно» Ашиша Васвани и соавт. (Ashish Vaswani, Attention Is All You Need, <https://arxiv.org/abs/1706.03762>). Исследовательская организация Google Brain по глубокому обучению в рамках Google AI осуществила раннее внедрение аналогичного механизма внимания в ResNet. Прогресс в шаблонах для структурированных данных эволюционировал аналогичным образом с внедрением шаблона широкой и глубокой модели, описанного в 2016 году в статье Хэн-Цзе Ченг и соавт. «Широкое и глубокое обучение для рекомендательных систем» (Tze Cheng, Wide & Deep Learning for Recommender Systems, <https://arxiv.org/abs/1606.07792>), опубликованной в агностичной к технологиям исследовательской группе Google Research.

Хотя, рассказывая об эволюции и современном состоянии дел в шаблонах конструирования, я сосредоточиваюсь на компьютерном зрении, где это уместно, я ссылаюсь на соответствующий прогресс в понимании естественного языка (NLU) и структурированных данных. Многие концепции в этой книге перекрестно применимы ко всем сферам и типам данных. Например, главы 2–4 охватывают универсальные основы, а все главы, кроме одной главы в части III, охватывают концепции, которые являются агностичными к модели и типу данных.

В главах, где это имеет смысл, в основном в части II, я привожу пример из области, выходящей за рамки компьютерного зрения. Например, в главе 5 я сравниваю разработку остаточных блоков с отождествляющими связями с вниманием в трансформерах для понимания естественного языка (NLU). В главе 6 мы проведем разведывательный анализ релевантности широких сверточных нейросетей для разработок в широких и глубоких и TabNet-моделях для структурированных данных. В главе 9 объясняется сопоставимость автокодировщиков с вложениями в понимании ЕЯ, а в главе 11 рассматривается сопоставимость шагов переноса обучения с пониманием ЕЯ и со структурированными данными.

Отталкиваясь от примеров, которыми я с вами делюсь из компьютерного зрения, обработки естественного языка (NLP) и структурных данных, вы должны быть в состоянии адаптировать концепции, методы и технические приемы к задачам в вашей области.

1.2 Эволюция подходов, основанных на машинном обучении

В целях понимания современного подхода сначала необходимо понять, где мы находимся с ИИ и машинным обучением и как мы сюда попали. В этом разделе представлено несколько подходов и шаблонов конструирования верхнего уровня для работы в современной производственной среде, включая интеллектуальную автоматизацию, машинное конструирование, сращивание моделей и консолидацию моделей.

1.2.1 Классический ИИ против узкого ИИ

Давайте вкратце рассмотрим разницу между классическим ИИ и современным узким ИИ. В классическом ИИ (также именуемом семантическим ИИ) модели конструировались как системы, основанные на правилах. Эти системы использовались для решения задач, которые невозможно было решать с помощью математического уравнения. Вместо этого система организовывалась так, чтобы имитировать профильного эксперта, или эксперта в предметной области. На рис. 1.1 представлен наглядный пример такого подхода.

Классический ИИ хорошо работал в низкоразмерных входных пространствах (например, имел малое число отдельных входных значений); имел входное пространство, которое можно было разбить на дискретные сегменты, такие как категории или корзины; и поддерживал сильную линейную взаимосвязь между дискретным пространством и выходом. Профильный эксперт конструировал набор правил, основанных на входных данных и преобразованиях состояний, которые имитировали его опыт. Затем программа конвертировала эти

правила в систему, основанную на правилах, обычно в форме «Если A и B истинны, то C истинно».

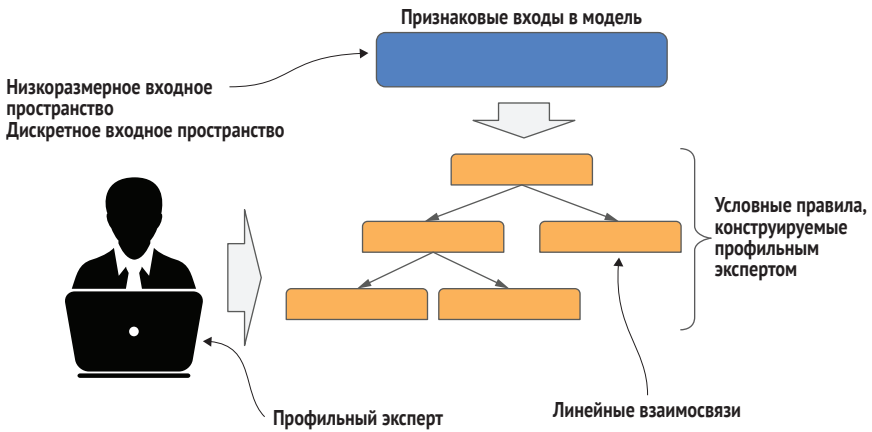


Рис. 1.1 В классическом подходе к ИИ профильный эксперт конструирует правила, имитирующие его знания

Подобного рода системы хорошо подходили для таких задач, как предсказывание качества и пригодности вина, что требовало лишь небольшого набора правил. Например, для селектора вин входными данными могли быть: обед или ужин, основное блюдо, повод и наличие десерта. Но классический ИИ не был способен масштабироваться до более крупных задач; точность резко падала, и правила требовали постоянного совершенствования, чтобы попытаться оттянуть падение. Неувязки между профильными экспертами, которые конструировали эти правила, были еще одной проблемой, приводящей к неточностям.

В узком ИИ (также именуемом *статистическим ИИ*) модель тренируют на крупном объеме данных, что уменьшает потребность в профильных экспертах. Вместо них в модели используются принципы статистики, позволяющие ей усваивать закономерности в распределении входных данных, т. н. *выборочном распределении*. Затем эти закономерности могут применяться высокоточно к образцам, которые не были замечены во время тренировки. После тренировки с использованием выборочного распределения, состоящего из крупных объемов данных, являющихся весомыми представителями более крупной популяции, или *популяционного распределения*, можно безгранично моделировать задачи, которые возникают в классическом ИИ. Другими словами, узкий ИИ очень хорошо может работать с существенно более высокой размерностью во входном пространстве (имея в виду крупное число несхожих входных данных) и с входными данными, которые могут быть как дискретными, так и непрерывными.

Давайте сопоставим ИИ, основанный на правилах, с узким ИИ, применив оба к предсказыванию продажной цены дома. Система,

основанная на правилах, обычно может учитывать лишь малый объем входных данных, например размер участка, площадь, число спален, число ванных и налог на имущество. Подобная система могла бы предсказывать среднюю цену для сопоставимых домов, но не для какого-либо отдельного дома из-за нелинейности во взаимосвязях объекта недвижимости с ценой.

Давайте отступим на один шаг назад и обсудим разницу между линейной и нелинейной взаимосвязями. В *линейной взаимосвязи* значение одной переменной предсказывает значение другой. Например, предположим, что у нас есть функция $y = f(x)$, которую мы определяем как $2 \times x$. Значение y может быть предсказано со 100%-ной уверенностью для любого значения x . В *нелинейной взаимосвязи* значение y может быть предсказано только с распределением вероятностей для любого значения x .

Используя наш пример с жильем, мы могли бы попытаться задать $y = f(x)$ как *продажная цена = кв_метры × цена_в_расчете_на_кв_метр*. Реальность такова, что на *цену_в_расчете_на_кв_метр* влияет множество других переменных, причем существует некоторая неопределенность в том, как они влияют на цену. Другими словами, квадратный метр дома имеет нелинейную взаимосвязь с продажной ценой, которая сама по себе может предсказывать только распределение вероятностей продажной цены.

В узком ИИ мы существенно увеличиваем число входов, чтобы усваивать нелинейности, например добавляем год постройки дома, дату выдачи разрешений на модернизацию, тип архитектуры, материалы, используемые для кровли и фасадного покрытия, информацию о школьном округе, возможности трудоустройства, средний доход, район, а также преступность и близость к паркам, общественному транспорту и автомагистралям. Эти дополнительные переменные помогают модели усваивать распределение вероятностей с высокой степенью уверенности. Входы, значение которых проистекает из фиксированного множества, такого как архитектура здания, являются *дискретными*, а входы, поступающие из неограниченного диапазона, такого как средний доход, являются *непрерывными*.

Модели узкого ИИ хорошо работают с входами, которые имеют высокий уровень нелинейности по отношению к выходам (предсказаниям), за счет усвоения границ, которые сегментируют входы, — опять же, если эти сегменты имеют строго линейную взаимосвязь с выходами. Такие типы моделей основываются на статистике, требуя крупных объемов данных, и называются *узким ИИ*, потому что они хороши в решении узких задач, состоящих из лимитированного круга задач внутри одной области. Узкие модели не так хороши в обобщении на задачи широкого масштаба. Рисунок 1.2 иллюстрирует подход на основе узкого ИИ.

Увидеть разницу между классическим ИИ и узким ИИ можно иначе, а именно глядя на снижение частоты ошибки в обоих типах моделей, поскольку глубокое обучение постоянно приближается к байесовому

теоретическому пределу ошибки. Байес описал этот теоретический предел ошибки в виде прогрессии, как показано на рис. 1.3.




Рис. 1.2 В узком ИИ модель учится быть профильным экспертом, тренируясь на крупном наборе данных, являющемся весомым представителем более крупной популяции

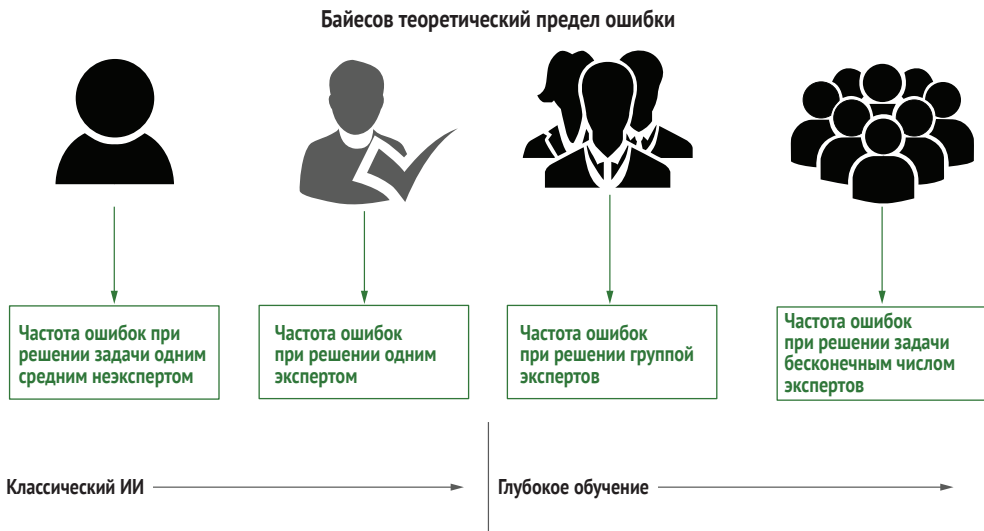


Рис. 1.3 Машинное обучение продвинулось к байесовому теоретическому пределу ошибки

Прежде всего какова будет частота ошибок при решении задачи одним средним неэкспертом? Затем какова будет частота ошибок при решении задачи одним экспертом (это аналогично семантиче-

скому ИИ)? Какова будет частота ошибок при решении задачи группой экспертов? И наконец, теоретический предел: какова будет частота ошибок при решении задачи бесконечным числом экспертов?

Глубокое обучение в огромном числе задач компьютерного зрения и обработки естественного языка (NLP) позволило достичь частоты ошибок группой экспертов, значительно превысив как традиционные программные приложения, так и экспертные системы. В 2020 году исследователи и инженеры машинного обучения на производственных предприятиях начали разрабатывать производственные системы, которые соответствуют байесовому теоретическому пределу ошибки.

1.2.2 Следующие шаги в компьютерном обучении

Теперь, когда мы понимаем, как мы сюда попали, осталось выяснить, где, собственно говоря, мы находимся. По мере того как компьютерное обучение менялось, мы сначала переходили от искусственного интеллекта к интеллектуальной автоматизации. А затем к машинному конструированию, сращиванию моделей и консолидации моделей. Давайте дадим определения этим современным достижениям.

ИНТЕЛЛЕКТУАЛЬНАЯ АВТОМАТИЗАЦИЯ

Как мы только что увидели, ранний искусственный интеллект означал классический ИИ, который основывался главным образом на правилах и требовал наличия профильных экспертов. Это позволило нам, по сути, написать программно-информационное обеспечение, чтобы начать автоматизировать задачи, которые обычно выполнялись вручную. Затем, в узком ИИ, мы применили статистику к самообучению, или усвоению, устранив необходимость в профильном эксперте.

Следующим крупным достижением стала *интеллектуальная автоматизация* (ИА, intelligent automation, аббр. IA). В этом подходе модели усваивают (почти) оптимальный способ автоматизирования процесса, превосходящий производительность и точность ручного или компьютерно-автоматизированного визави.

В типичной ситуации система ИА работает как конвейерный процесс. Кумулятивная информация, преобразования и переходы из состояния в состояние являются данными, которые поступают на вход модели в различных точках конвейера. Данные на выходе, или предсказание, из каждой модели используются для выполнения следующего преобразования информации и/или принятия решения о следующем переходе из состояния в состояние. В типичной ситуации каждая модель тренируется и развертывается независимо, обычно в виде микрослужбы, при этом всем конвейерным процессом руководит приложение серверного типа (внутреннее или бэкендовое).

Примером ИА является автоматизированное выделение информации о пациентах из медицинских записей из различных источников и форматов, включая источники, на которых модель никогда не тренировалась. В 2018-м я работал над архитектурным дизайном таких систем в области здравоохранения. Сегодня целый ряд поставщиков предлагают такие системы «под ключ»; Google Cloud Healthcare API (<https://cloud.google.com/healthcare>) является одной из них.

В 2019 году в огромном числе компаний размера промышленного предприятия ИИ двигался в сторону полноценного производства. В течение того года я проводил все большее число встреч с крупнейшими клиентами Google. И сейчас давайте поговорим об ИИ с точки зрения бизнеса. Упомянутые выше технологические концепции превратились в деловые концепции.

На этих встречах мы отошли от использования ИИ и заменили его на ИА, чтобы демистифицировать процесс. Мы просим клиента описать каждый шаг (ручной и компьютеризированный) в процессе, к которому они хотят применить ИИ. Предположим, что один шаг стоит 100 000 долларов. В прошлом нашей тенденцией было бы прыгнуть к этому шагу и применить ИИ – «большую награду». Но предположим, что еще один шаг стоит всего копейки, но случается миллион раз в день – а это 10 000 долларов в день, или 3.65 млн долларов в год. И давайте предположим, что мы могли бы заменить этот спелый и сочный плод моделью, которая усваивает оптимальный способ автоматизирования данного шага и которая в оперативном плане стоит 40 000 долларов в год. Ведь никто не оставит на столе 3.61 млн долларов.

Это и есть интеллектуальная автоматизация. Вместо того чтобы программисты кодировали ранее разработанный алгоритм автоматизации, программисты ориентируют модель, чтобы та разумно усваивала оптимальный алгоритм. На рис. 1.4 показано применение ИА к отдельному шагу в конвейере обработки заявок.

Давайте проведем высокоуровневый обзор происходящего в этом конвейере. На шаге 1 относящиеся к заявке документы сканируются и подаются в конвейер ИА. На шаге 2 предшествующая практика оператора документов, который поочередно просматривает каждый отсканированный документ и его размечает, заменяется естественно-языковой классификационной моделью, которая была натренирована выполнять эту задачу обработки заявок.

Это замещение имеет ряд преимуществ. Во-первых, исключается стоимость ручного труда. В дополнение к повышению скорости работы за счет компьютера по сравнению с человеком указанный процесс можно распределить таким образом, что можно будет обрабатывать массовое число документов в параллельном режиме.

Во-вторых, частота ошибок на правильной разметке классов документа существенно снижается по сравнению с частотой ошибок людей. Давайте подумаем, почему. Каждый человек-оператор имеет разный уровень подготовки и опыта, а также большое непостоянство

(дисперсию) в точности. Кроме того, увеличению частоты ошибок способствует усталость человека. Но давайте предположим, что мы располагаем одной тысячей обученных операторов-людей, которые просматривают один и тот же документ(ы), и для маркировки документа мы используем метод мажоритарного голосования. Мы ожидаем, что частота ошибок будет существенно снижена, приблизившись к нулю.

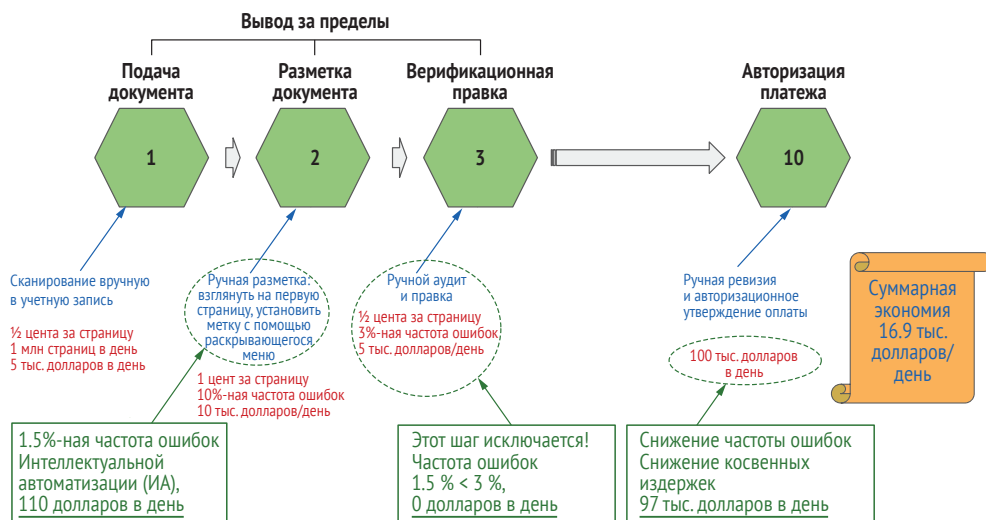


Рис. 1.4 Интеллектуальная автоматизация, применяемая для обработки заявок

Именно это и делает модель: она была натренирована на огромном числе документов, которые были помечены огромным числом обученных людей-операторов. Таким образом, после тренировки результативность модели равна результативности коллектива обученных людей-операторов.

На шаге 3 в ручной версии опытный оператор-человек инспектирует разметку, чтобы еще больше уменьшить число ошибок. Этот этап в процессе ИА не исключается, но благодаря существенному сокращению ошибок по сравнению с этапом 2 рабочая нагрузка на человека-оператора значительно снижается.

Нижестоящие процессы ИА продолжают снижать/устранять издержки на человека-оператора и еще больше снижать частоту ошибок. Как только мы перейдем к заключительному шагу, обученный профильный эксперт (subject-matter expert, аббр. SME) проводит заключительную ревизию на предмет авторизации (или неавторизации) платежа. Теперь, когда рассматриваемая профильным экспертом информация имеет более высокую точность, субъективное решение человека получается более надежным, что еще больше снижает издержки на принятие неправильного субъективного решения.

Мы в отрасли перестали использовать термин *машинное обучение* и заменили его *машинным конструированием*, чтобы провести аналогию с *компьютерным конструированием* (computer-aided design, аббр. CAD). Компьютерное конструирование применялось к задачам, которые были слишком сложными, чтобы разрабатывать даже субоптимальное решение. Эти системы имели строительные компоненты, математические знания и правила экспертной системы, а профильные эксперты ориентировали системы компьютерного конструирования, чтобы те отыскивали хорошее субоптимальное решение.

В отличие от них, в машинном конструировании система усваивает строительные компоненты, математические знания и правила сама, а инженер машинного обучения ориентирует машинное конструирование, чтобы то отыскивало оптимальное решение. Переходя к машинному конструированию, мы высвобождаем ценные человеческие ресурсы для решения сложных задач следующего уровня, ускоряя техническое развитие людей и обеспечивая бизнесу более высокую возвратность инвестиций (ROI) в расчете на одного сотрудника.

МАШИННОЕ КОНСТРУИРОВАНИЕ

До глубокого обучения профильные эксперты разрабатывали программно-информационные продукты для проведения поиска хороших решений в тех частях программно-информационного и аппаратного обеспечения, которые отличались высокой сложностью. Как правило, эти программы представляли собой комбинацию поисковой оптимизации и методов, основанных на правилах.

В следующем продвижении вперед, *машинном конструировании* (machine design), модели усваивают (почти) оптимальный способ конструирования и интегрирования программно-информационных и аппаратных компонентов. Эти системы превосходят по производительности, точности и сложности, даже если их сравнивать с моделями, разработанными профильными экспертами с помощью программы CAD. Конструктор-человек использует свой опыт работы в реальном мире, чтобы ориентировать поиск решений, проводимый моделью в пространстве поиска.

Рассмотрим больницу с двумя рентгеновскими отделениями; в одном отделении установлен дорогой рентгеновский аппарат, а в другом – недорогой. Осматривающий врач выбирает отделение, в которое направлять пациента для подтверждения диагноза пневмонии, *в зависимости от правдоподобной возможности, что у пациента есть пневмония*. Если такая возможность пневмонии невелика или маловероятна, то врач направляет пациента на недорогой рентгеновский аппарат, руководствуясь страховым полисом и желанием снизить расходы для страховой компании. Если определение является высоким или возможным, то пациент заслуживает дорогостоящего рентгеновского снимка. Это пример машинного конструирования, наполняющего пространство гиперпараметрического и архитектурного

поиска информацией, ориентирующий конвейер в системе автоматического усвоения медицинских снимков из разных распределений (медицинских устройств, в данном случае рентгеновских аппаратов).

Имейте в виду, что если для тренировки модели используются накопительные рентгеновские лучи и диагностические определения от двух рентгеновских устройств, то у нас будет смещение в данных. Вместо того чтобы учиться на данных, модель может непреднамеренно усвоить уникальные характеристики этих двух медицинских устройств – то есть смещение вследствие *точки зрения*. Классическим примером проблемы смещения в модели вследствие точки зрения является случай определения разницы между собаками и волками, в котором модель непреднамеренно усвоила снег как атрибут волков, поскольку все тренировочные снимки волков были сделаны зимой.

В машинном конструировании, помимо тренировки модели, система усваивает оптимальный тренирующий конвейер для антагонистической модели, именуемой *суррогатом*. Если вы хотите углубиться в эту тему подробнее, то статья «Антагонистический подход для устойчивого классифицирования пневмонии по рентгенограммам грудной клетки» (<https://arxiv.org/pdf/2001.04051.pdf>) является основополагающей работой по машинному конструированию, которая имеет прямую связь с упомянутой проблематикой.

СРАЩИВАНИЕ МОДЕЛЕЙ

Сращивание моделей (model fusion) представляет собой следующий шаг в разработке более точных и недорогих систем для предсказательного технического сопровождения и обнаружения неисправностей наподобие тех, которые используются в сенсорных системах интернета вещей. Традиционно датчики интернета вещей встраивались в очень дорогое оборудование и инфраструктуру, такие как заводские станки, самолеты и региональные энергетические инфраструктуры. Непрерывные данные от этих датчиков передавались в разработанные экспертами алгоритмы, которые опирались на правила.

Проблема с этими традиционными системами заключалась в том, что они подвержены высокому непостоянству (дисперсии) окружающей среды, что влияет на их надежность. Например, в электроэнергетике на каждой вышке линии электропередачи установлены датчики, которые отслеживают наличие аномалий в линейном импедансе между вышками. Импеданс может колебаться в результате давления на линейное соединение из-за ветра, изменений температуры, влияющих на проводимость, и вторичных факторов, таких как накопление влаги.

Сращивание моделей повышает надежность систем интернета вещей посредством задействования машинно-усвоенной модели с более высокой операционной стоимостью с целью генерирования помеченных данных, чтобы конвертировать систему, сконструированную экспертом. Продолжая наш пример с энергетикой, сегодня там используются беспилотные летательные аппараты и модели глу-

бокого обучения, натренированные в компьютерном зрении, чтобы периодически проводить инспекцию линий электропередач. Этот процесс является высокоточным и в операционном плане более дорогостоящим.

Вследствие этого он используется для того, чтобы генерировать помеченные данные для сенсорных импедансных данных, создаваемых более дешевой сенсорной системой. Помеченные данные, сгенерированные с высокой операционной стоимостью, затем используются для тренировки еще одной модели, которую импедансные датчики (недорогая система) затем применяют для достижения сопоставимой надежности.

Консолидация моделей

До глубокого обучения приложения создавались либо как монолитное, работающее на внутреннем (бэкендовом) сервере, либо как стержневая магистраль на сервере, использующем распределенные микрослужбы. В *консолидации моделей* модель (модели) по существу становится целым приложением, которое напрямую обменивается модельными компонентами и выходными данными и усваивает коммуникационный интерфейс между моделями. Все это происходит без необходимости в громоздком приложении серверного типа или микрослужбах.

Вообразите модельный конвейер для индустрии недвижимости, в котором используется анализ изображений на фотографиях домов и многоквартирных жилых зданий, чтобы определять расценки арендной платы. Модели внутри набора выстроены в цепочку, причем каждая модель натренирована на отдельной функциональности; вместе они автоматически определяют арендные условия, арендные удобства и привлекательность рынка и предлагают соответствующие расценки.

Давайте сравним это с более традиционным ИА, где каждый шаг в конвейере процесса является отдельным развернутым экземпляром модели, принимающим на входе изначальное изображение либо преобразование и состояние, все из которых контролируются основным на правилах приложением серверного типа, разработанным экспертом(ами). Напротив, в консолидации экземпляры моделей обмениваются друг с другом напрямую. Каждая модель усвоила оптимальный метод выполнения своей специализированной работы (например, определение состояния); усвоила оптимальный путь обмена информацией и представление между моделями (моделями для дома, комнаты и удобств), а также усвоила оптимальный метод определения изменений состояния (условий объекта недвижимости).

Я ожидаю, что на уровне предприятия в 2021 году производство перейдет к консолидации моделей. Мы все еще пытаемся понять, как сделать так, чтобы все это работало как надо. До консолидации развешивалось большое число моделей, которые выполняли разные за-

дачи, и разработчики конструировали приложение серверного типа, которое осуществляло передачу состояния представления данных (REST) или вызывало микрослужбы. Мы по-прежнему кодировали логику приложения, а также интерфейс и обмен данными между приложением и моделями. На рис. 1.5 приведен пример консолидации моделей, которую я разработал в конце 2019 года для спортивного вещания.

Давайте пройдемся по этому процессу пошагово. В начале консолидация принимает видео в реальном времени; то есть консолидация обрабатывает видео непрерывно. Видео разбирается на части в реальном времени как набор кадров, расположенный во временной последовательности. Каждый кадр представляет собой изображение спортивного игрока, например бейсболиста, который вот-вот выполнит удар битой. Каждый кадр сначала обрабатывается совместным набором сверточных слоев (совместными сверточными слоями), который генерирует общую внутреннюю кодировку для нижестоящих задач. Другими словами, вместо того чтобы каждая нижестоящая задача (модель) начиналась с одного и того же входного изображения и обрабатывалась во внутреннюю кодировку, входное изображение кодируется один раз, а кодировка реиспользуется в нижестоящих компонентах. Это ускоряет отклик модели и сокращает ее размер в памяти.



Рис. 1.5 Консолидация моделей применительно к спортивному вещанию

Затем сгенерированная общая кодировка проходит через модель обнаружения объектов, натренированную на общей кодировке вместо изображения на входе, сокращая размер и увеличивая скорость обнаружения объектов. Допустим, модель обнаружения объектов натренирована распознавать объекты, включая людей, игровое оборудование, персонал и поле. Для каждого объекта, который модель распознает в кадре, она будет выводить вложение уровня объекта, то есть низкоразмерное отображение/представление (например, коди-

ровку сокращенного размера) вместе с пространственными координатами внутри вышестоящего входного кадра.

Эти объектно-уровневые вложения теперь становятся входами для еще одного набора нижестоящих задач. Затем вы видите, что вложения, классифицированные как люди, передаются в модель распознавания лиц, которая была натренирована на вложениях, а не на изначальных изображениях. Модель может быть натренирована, например, распознавать игроков, официальных лиц, судей, тренеров и службу безопасности и соответственно помечать вложение. Объектные вложения, специфичные для каждого игрока, затем передаются в модель оценивания поз, которая отыскивает ключевые точки человека и классифицирует позу идентифицированного человека в кадре, например игрок А находится в положении отбивающего.

Затем вложения уровня объектов (игроки, механизмы, стадион и т. д.) объединяются с конкретной позой игрока в информационно обогащенное плотное вложение. И вся эта насыщенная информация передается в еще одну модель для предсказания действий игрока, например игрок А находится у возвышения, готовый бросить мяч. Это предсказывающее действие потом передается в еще одну модель, конвертирующую действие в текст в виде закрытых субтитров, который накладывается на прямую трансляцию.

Давайте допустим, что спортивное событие транслируется по всему миру и его смотрят зрители на самых разных языках. Данные на выходе из модели аннотирования изображений (например, на английском языке) передаются в еще одну модель, которая выполняет перевод на язык, специфичный для каждого рынка. На каждом рынке переведенный текст конвертируется в речь для комментариев в реальном времени.

Как видите, модели эволюционировали от однозадачных предсказаний и автономных развертываний в модели, которые выполняют несколько задач, совместно используют модельные компоненты и интегрированы, чтобы формировать решения, такие как в примерах обработки медицинских документов и спортивного вещания. Такие интегрированные модельные решения можно описать и по-другому, как *конвейер обслуживания*. Конвейер состоит из соединенных между собой компонентов; выход из одного компонента является входом в другой, и каждый компонент можно конфигурировать, заменять, и каждый из них имеет версионный контроль и историю. Использование конвейеров в современном производственном машинном обучении распространяется на весь сквозной конвейер целиком.

1.3 Выгоды от шаблонов конструирования

До 2017 года большинство версий нейросетевых моделей во всех областях кодировались в стиле пакетных сценариев. По мере того как исследователи ИИ и опытные инженеры-программисты все активнее

вовлекались в исследования и конструирование, мы начали замечать сдвиг в кодировании моделей, отражавший принципы инженерии программно-информационного обеспечения, ориентированные на реиспользование и шаблоны конструирования.

Из *шаблона конструирования* следует, что существует лучший образец практики строительства и кодирования модели, который может применяться повторно в широком диапазоне случаев, таких как классифицирование изображений, обнаружение и отслеживание объектов, распознавание лиц, сегментирование изображений, наделение сверхразрешающей способностью и перенос стиля для данных, связанных со снимками и изображениями; классифицирование документов, анализ настроений, выделение сущностей и резюмирование текстовых данных; а также классифицирование, регрессия и предсказывание для неструктурированных данных.

Развитие шаблонов конструирования для глубокого обучения привело к консолидации моделей, сращиванию моделей и машинному конструированию, в которых модельные компоненты могут реиспользоваться и адаптироваться. Такие шаблоны конструирования модельных компонентов позволили исследователям и другим практикам глубокого обучения поступательно развивать как модельные компоненты, так и лучшие образцы практики для приложений, по всем моделям и по всем типам данных. Этот обмен знаниями ускорил развитие шаблонов конструирования и реиспользование модельных компонентов, что позволило развертывать глубокое обучение в широко распространенных производственных приложениях.

Многие исторически передовые модели, которые я рассматриваю в этой книге, раскрывают знания и концепции, встроенные в современное производство сегодняшнего дня. Несмотря на то что многие из этих моделей в конечном итоге перестают использоваться, понимание знаний, концепций и компонентов, лежащих в их фундаменте, имеет важное значение для практики глубокого обучения в современных крупных масштабах.

Одним из самых ранних шаблонов конструирования нейросетевых моделей стал шаблон *процедурного реиспользования* (procedural reuse), который был принят одновременно и повсеместно в компьютерном зрении, понимании естественного языка (NLU) и структурированных данных. Как и в случае с программно-информационным приложением, модель процедурного реиспользования конструируется в виде компонентов, которые отражают поток данных и раскладывают компоненты на реиспользуемые функции.

Многочисленные выгоды от применения шаблона процедурного реиспользования были и есть. Во-первых, он упрощает задачу представления моделей в архитектурных диаграммах. До использования формального шаблона каждый коллектив исследователей изобретал в публикуемых им статьях свой собственный способ представления своей модельной архитектуры. Указанный шаблон конструирования также определяет представление, которое задействуется для

структуры и потока модели. Наличие выверенного и усовершенствованного метода упростило изображение архитектурных диаграмм. Во-вторых, модельные архитектуры легче понимать другим исследователям и инженерам машинного обучения. Кроме того, работа по стандартному шаблону раскрывает внутреннюю работу конструкции, что, в свою очередь, облегчает работу по модифицированию моделей, устранению неполадок и проведению отладки.

В 2016 году авторы исследовательских статей начали показывать поток компонентов, традиционно именуемых *стержнем*, (представительным) *учеником* и (преобразовательной) *задачей*. До 2016 года авторы исследовательских работ представляли свои модели в виде монолитной архитектуры. Эти монолитные архитектуры усложняли исследователям задачу выстраивания доказательств того, что новая концепция являлась усовершенствованием любой отдельной части модели. Поскольку эти компоненты содержат повторяющиеся шаблоны потоков, в конечном итоге появилась концепция конфигурируемых компонентов. Эти повторяющиеся шаблоны потоков впоследствии реиспользовались и совершенствовались другими исследователями при конструировании своих модельных архитектур. Несмотря на то что применение модельных компонентов отставало в отрасли понимания естественного языка (NLU) и структурированных данных, к 2017 году мы начали встречать их появление в исследовательских работах и там. Сегодня, независимо от типа и сферы модели, модельная конструкция состоит из все тех же сопоставимых трех первичных модельных компонентов.

Более ранней версией шаблона конструирования, раскладывающего модель на компоненты, была архитектура SqueezeNet (<https://arxiv.org/pdf/1602.07360.pdf>), в которой использовались конфигурируемые компоненты на основе метапараметров. Введение метапараметров, описывающих процедуру конфигурирования модельных компонентов, помогло формализовать представление, конструкцию и имплементацию конфигурируемых компонентов. Разработка моделей на основе конфигурируемых компонентов предоставила исследователям возможность измерять улучшения производительности на покомпонентной основе, пробуя различные конфигурации компонентов. Такой подход к конструированию является стандартной практикой при разработке прикладного программно-информационного обеспечения; среди его многочисленных преимуществ следует отметить стимулирование им реиспользования исходного кода.

Шаблоны процедурного реиспользования были первыми и остаются наиболее фундаментальными реиспользуемыми конструкциями, поэтому они находятся в центре внимания данной книги. Позже для машинного конструирования будут введены так называемые шаблоны фабрики и абстрактной фабрики. В *фабричном шаблоне* конструирования в качестве фабрики и цели используются передовые строительные блоки, чтобы проводить поиск наилучшей соот-

ветствующей требованиям конструкции. *Абстрактный фабричный шаблон* абстрагируется на еще один уровень ниже и ищет наилучшую фабрику, которая затем используется для поиска наилучшей модели.

Однако в этой книге вы узнаете краеугольные конструкции, начав в части I с архитектур базовых глубоких нейросетей и сверточных нейросетей, перейдя в части II к эпохальным моделям, кодированным для процедурного реиспользования, и закончив в части III экскурсией по современному производственному конвейеру.

Резюме

- Глубокое обучение эволюционировало от классического ИИ к узкому ИИ, что привело к использованию ИИ для решения задач с высокоразмерными входными данными.
- Глубокое обучение эволюционировало от экспериментов с моделями к подходу на основе реиспользуемого и переконфигурируемого конвейера для обработки данных, тренировки, развертывания и обслуживания производственных запросов.
- Практики машинного обучения, работающие на переднем крае в масштабах производственного предприятия, используют консолидацию моделей, сращивание моделей и машинное конструирование.
- Шаблон процедурного реиспользования является строительным блоком и располагается непосредственно на переднем крае сегодняшнего дня в масштабе производственного предприятия.

Глубокие нейронные сети



Эта глава охватывает следующие ниже темы:

- разложение структуры нейронных и глубоких нейронных сетей;
- использование прямого и обратного распространения во время тренировки для усвоения модельных весов;
- кодирование нейросетевых моделей в последовательном и в функциональном API TF.Keras;
- понимание различных типов модельных задач;
- использование стратегий предотвращения переподгонки.

Эта глава начинается с нескольких основ нейронных сетей. После того как вы разберетесь в основах, я познакомлю вас с тем, как глубокие нейросети можно легко кодировать с помощью модуля TF.Keras¹, в котором есть два стиля кодирования нейронных сетей: последовательный стиль (или последовательный API) и функциональный стиль (или функциональный API). Мы будем программировать примеры, используя оба стиля.

Эта глава также охватывает основополагающие типы моделей. Каждый тип модели, такой как регрессия и классификация, усваивает разные типы задач. Задача, которую вы хотите усвоить, определяет тип модели, которую вы будете конструировать. Вы также изучите основы весов, смещений, активаций и оптимизаторов, а еще узнаете о том, как они обеспечивают точность модели.

¹ То есть имплементации спецификации API Keras в Tensorflow. – Прим. перев.

Завершая эту главу, мы закодируем классификатор изображений. И наконец, я расскажу о проблеме перепогонки во время тренировки, а также о предварительном подходе к решению этой проблемы с помощью отсева.

2.1 Основы нейронных сетей

Давайте начнем с нескольких основ нейронных сетей. В этом разделе сначала рассматривается входной слой нейронной сети, затем его соединение с выходным слоем и далее добавление между ними скрытых слоев, что делает нейронную сеть глубокой. После этого мы остановимся на том, как составлять слои из узлов, выясним, что узлы делают и как слои соединяются друг с другом, формируя полносвязные нейронные сети.

2.1.1 Входной слой

Входной слой нейронной сети принимает числа! Все поступающее на вход данные конвертируются в числа. Все вокруг нас является числами. Текст, речь, картинки становятся числами, а вещи, которые уже являются числами, просто остаются числами.

Нейронные сети принимают числа в виде векторов, матриц либо тензоров. Все то просто имена для числа размерностей в массиве. Вектор – это одномерный массив, такой как список чисел. Матрица – это двумерный массив, подобный пикселям на черно-белом изображении. А тензор – это любой массив из трех или более размерностей, например стопка (стек) матриц, в которых каждая матрица имеет одинаковую размерность. Вот и все. Рисунок 2.1 иллюстрирует эти концепции.

Если говорить о числах, то вы, возможно, слышали такие термины, как нормализация или стандартизация. При стандартизации числа конвертируются так, чтобы они были центрированы вокруг среднего значения, равного нулю, с одним стандартным отклонением с каждой стороны от среднего.

Если вы прямо сейчас скажете, что не особо сильны в статистике, то я пойму ваши чувства. Но не волнуйтесь. Такие пакеты, как `scikit-learn` (<https://scikit-learn.org>) и `NumPy` (<https://numpy.org>), имеют библиотечные вызовы, которые делают это за вас. Стандартизация – это, по сути, кнопка, которую нужно нажать, и для этого даже не нужен рычаг, поэтому никаких параметров устанавливать не потребуется.

Говоря о пакетах, вы будете часто использовать `NumPy`. Что такое `NumPy`, и почему он так популярен? Учитывая интерпретирующую природу языка `Python`, он слабо справляется с крупными массивами – то есть действительно большими, сверхкрупными массивами чисел – из тысяч, десятков тысяч и миллионов чисел. Подумайте

о печально известной цитате Карла Сагана о размерах Вселенной: миллиарды и миллиарды звезд. Это и есть тензор!

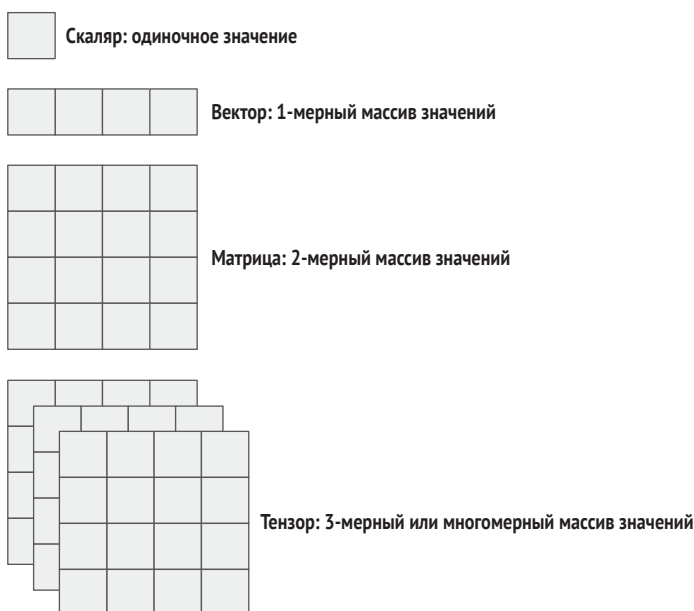


Рис. 2.1 Типы массивов в глубоком обучении

Однажды программисту на языке С пришла в голову идея написать на низкоуровневом языке С высокопроизводительную имплементацию для манипулирования сверхкрупными массивами, а затем добавить внешнюю обертку на Python. Так родился NumPy. Сегодня NumPy представляет собой библиотеку с многочисленными полезными методами и свойствами, такими как свойство `shape`, которое сообщает вам форму (или размерности) массива, и метод `where()`, который позволяет выполнять SQL-подобные запросы к вашему сверхкрупному массиву.

Все Python'овские вычислительные каркасы машинного обучения, такие как TensorFlow и PyTorch, во входном слое будут принимать на входе многомерный массив NumPy. И говоря о С, или Java, или C++, входной слой в нейронной сети – это все равно, что параметры, передаваемые функции на языке программирования. Вот и все.

Давайте начнем с установки пакетов Python, которые вам понадобятся. Я предполагаю, что у вас установлена версия 3.x языка Python (www.python.org/downloads/). Независимо от того, установили вы его напрямую либо в рамках более крупного пакета, такого как Anaconda (www.anaconda.com/products/enterprise), вместе с ним вы получили отличный инструмент командной строки под названием `pip`. Этот инструмент используется для установки любого пакета Python, который вам когда-либо понадобится снова,

вызовом всего одной команды. Вы применяете `pip install`, а затем имя пакета. Он переходит в каталог пакетов Python (Python Package Index, аббр. PyPI), т. е. глобальное хранилище пакетов Python, скачивает и устанавливает пакет за вас. Все довольно просто.

Мы хотим начать со скачивания и installations вычислительного каркаса TensorFlow и пакета Numpy. И знаете что? Их имена есть в каталоге, `tensorflow` и `numpy` – и, к счастью, очень очевидные. Давайте сделаем это вместе. Перейдите в командную строку и исполните следующие ниже команды:

```
pip install tensorflow
pip install numpy
```

В каркас TensorFlow 2.0 встроен модуль Keras и рекомендуемый модельный API, который теперь называется *TF.Keras*. *TF.Keras* основан на объектно-ориентированном программировании с коллекцией классов и ассоциированными с ними методами и свойствами.

Давайте начнем с простого. Допустим, у нас есть набор данных о жилье. Каждая строка содержит 14 столбцов данных. В одном столбце указана продажная цена дома. Мы будем называть ее *меткой*. В остальных 13 столбцах содержится информация о доме, такая как площадь и налог на имущество. Это все цифры. Мы будем называть их *признаками*. Мы хотим научиться предсказывать (или оценивать) метку по признакам.

Так вот, до того, как у нас появились все эти вычислительные мощности и эти потрясающие вычислительные каркасы машинного обучения, аналитики данных делали это вручную либо с помощью формул в электронной таблице Microsoft Excel с определенным объемом данных и большим объемом линейной алгебры. Однако мы будем использовать Keras и TensorFlow.

Мы начнем с того, что сначала импортируем модуль Keras из TensorFlow, а затем инстанцируем библиотечный класс `Input`, то есть создаем экземпляр этого класса. Для этого класса мы определяем форму или размерности входных данных. В нашем примере входные данные представляют собой одномерный массив (вектор) из 13 элементов, по одному для каждого признака:

```
from tensorflow.keras import Input
Input(shape=(13,))
```

Когда вы выполните эти две строки в блокноте, то увидите вот такой результат:

```
<tf.Tensor 'input_1:0' shape=(?, 13) dtype=float32>
```

Этот результат показывает вам, во что оценивается инструкция `Input(shape=(13,))`. Она производит тензорный объект с именем `input_1:0`. Это имя будет полезно позже, помогая вам в отладке ваших моделей. Вопросительный знак (?) в `shape` показывает, что входной

объект принимает неограниченное число записей (примеров или строк) по 13 элементов в каждой. То есть во время выполнения он свяжет число одномерных векторов по 13 элементов каждый с фактическим числом передаваемых вами примеров (строк), именуемым *размером (мини-)пакета*. Слово `dtype` показывает тип данных, заданный у этих элементов по умолчанию, то есть в данном случае по умолчанию используется 32-битовый вещественный тип (числа с плавающей точкой одинарной точности).

2.1.2 Глубокие нейронные сети

Глубокий разум (DeepMind), глубокое обучение, глубокое, глубокий, глубокие. О боже, что все это значит? *Глубокий* в данном контексте просто означает, что нейронная сеть имеет один или несколько слоев между входным и выходным слоями. Как вы убедитесь позже, исследователи, углубившись в скрытые слои, смогли получить более высокую точность.

Нарисуйте в уме ориентированный граф в слоях глубины. Корневые узлы являются входным слоем, а терминальные узлы – выходным слоем. Слои между ними называются *скрытыми*, или *глубокими*, слоями. Таким образом, четырехслойная архитектура глубокой нейросети будет выглядеть следующим образом:

- входной слой;
- скрытый слой;
- скрытый слой;
- выходной слой.

Для начала мы предположим, что каждый нейросетевой узел в каждом слое, кроме выходного слоя, является нейросетевым узлом одинакового типа. Мы также допустим, что каждый узел в каждом слое связан с каждым другим узлом в следующем слое. Такая сеть называется полносвязной нейронной сетью (fully connected neural network, аббр. FCNN), и она изображена на рис. 2.2. Например, если входной слой имеет три узла, а следующий (скрытый) слой имеет четыре узла, то каждый узел в первом слое соединен со всеми четырьмя узлами в следующем слое – в общей сложности 12 соединений (3×4).

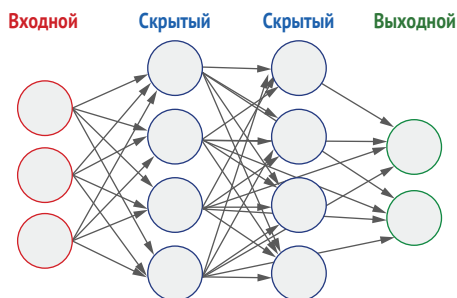


Рис. 2.2 Между входным и выходным слоями глубокой нейронной сети есть один или несколько скрытых слоев. Указанная сеть является полносвязной, поэтому узлы на всех уровнях связаны друг с другом

2.1.3 Сети прямого распространения

Глубокие нейросети и сверточные нейросети (в главе 3 вы узнаете о сверточных нейросетях больше) называются нейронными сетями прямого распространения. Прямое распространение означает, что данные перемещаются по сети последовательно, в одном направлении, от входного слоя к выходному слою. Это аналогично функции в процедурном программировании. Входные данные передаются в качестве параметров во входной слой, и функция, основываясь на входных данных, выполняет упорядоченный набор действий (в скрытых слоях), а затем выдает результат (выходной слой).

Занимаясь кодированием сети прямого распространения в TF. Keras, вы будете встречать в блог-постах и других учебных материалах два отличительных стиля. Я кратко коснусь обоих, поэтому когда вы увидите фрагмент исходного кода в одном стиле, то сможете перевести его в другой.

2.1.4 Метод последовательного API

Метод последовательного API легче читать и использовать новичкам, но зато он менее гибок. По сути, вы создаете пустую нейронную сеть прямого распространения с помощью библиотечного класса `Sequential`, а затем «добавляете» по одному слою за раз вплоть до выходного слоя. В следующих ниже примерах многоточия представляют псевдокод:

```
from tensorflow.keras import Sequential
```

```
model = Sequential()
model.add( ...первый слой... )
model.add( ...следующий слой... )
model.add( ...выходной слой... )
```

Создает пустую модель

Местоаполнители для добавления слоев в последовательном порядке

В качестве альтернативы слои могут быть указаны в последовательном порядке в виде списка, передаваемого в качестве параметра при инстанцировании класса `Sequential`:


```
model = Sequential([ ...первый слой...,
                     ...следующий слой...,
                     ...выходной слой...
                    ])
```

И значит, вы, возможно, спросите когда при инстанцировании класса `Sequential` следует использовать метод `add()`, а когда указывать список? Все дело в том, что оба метода генерируют одну и ту же модель и поведение, так что это вопрос личных предпочтений. В учебных и демонстрационных материалах я склонен использовать более подробный метод `add()`, делая это для ясности. Но если я пишу исходный код для производства, то использую более разряженный

списковый метод, где мне легче визуализировать и редактировать исходный код.

2.1.5 Метод функционального API

Метод функционального API более продвинут, позволяя вам создавать модели, которые не являются последовательными в потоке, такие как ветви, отождествляющие связи и многочисленные входы и выходы (в разделе 2.4 вы увидите работу нескольких входов и выходов). Вы строите слои отдельно, а затем связываете их вместе. Этот последний шаг дает вам свободу соединять слои в творческом ключе. По сути, для нейронной сети прямого распространения вы создаете слои, привязываете их к еще одному слою или слоям, а затем собираете все слои в финальной инстанцииции библиотечного класса `Model`:



2.1.6 Входная форма и входной слой

Входная форма и входной слой поначалу могут сбивать с толку. Это не одно и то же. Выражаясь конкретнее, число узлов во входном слое не обязательно должно соответствовать форме входного вектора. Это связано с тем, что каждый элемент во входном векторе будет передаваться каждому узлу во входном слое, как показано на рис. 2.3.

Например, если входной слой состоит из 10 узлов и мы используем предыдущий пример 13-элементного входного вектора, то между входным вектором и входным слоем будет 130 соединений (10×13).




Рис. 2.3 Вход (входная форма) и входной слой различаются. Каждый элемент во входном векторе соединен с каждым узлом во входном слое

Каждое соединение между элементом во входном векторе и узлом во входном слое имеет вес, и каждый узел во входном слое имеет смещение. Думайте о каждом соединении между входным вектором и входным слоем, а также о соединениях между слоями как о пере-

сылке сигнала, сообщаящего о том, насколько сильно он верит, что входное значение будет способствовать предсказаниям модели. Нам нужно измерить силу данного сигнала, и это как раз и делает вес. Это коэффициент, который умножается на входное значение для входного слоя и предыдущее значение для последующих слоев.

Так вот, каждое из этих соединений выглядит как вектор на плоскости $x-y$. В идеале мы хотим, чтобы каждый такой вектор пересекал ось y в одной и той же центральной точке (например, в начале координат 0). Но они не пересекают. Для того чтобы сделать векторы относительно друг друга, существует смещение, т. е. сдвиг каждого вектора от центральной точки на оси y .

Веса и смещения – это то, что нейронная сеть будет «усваивать» во время тренировки. Веса и смещения также называются *параметрами*. Указанные значения остаются в модели после ее тренировки. В иных ситуациях эта работа будет для вас невидимой.

2.1.7 Плотный слой

В модуле `TF.Keras` слои в полносвязной сети (FCNN) называются *плотными слоями*. Плотный слой имеет n узлов и полностью соединен с предыдущим слоем.

Давайте продолжим работу и определим трехслойную нейронную сеть в `TF.Keras`, используя в нашем примере метод последовательного API. Наш входной слой имеет 10 узлов и принимает на входе 13-элементный вектор (13 признаков), который соединен со вторым (скрытым) слоем из 10 узлов, который затем соединен с третьим (выходным) слоем из одного узла. Наш выходной слой должен быть только одним узлом, так как он будет выдавать одно действительное значение (например, предсказанную цену дома). В данном примере мы собираемся использовать нейронную сеть в качестве *регрессора*, а именно нейронная сеть будет выдавать одно действительное число:

Входной слой = 10 узлов

Скрытый слой = 10 узлов

Выходной слой = 1 узел

Для входного и скрытых слоев можно выбрать любое число узлов. Чем больше узлов, тем лучше нейронная сеть сможет учиться. Но большее число узлов означает более высокую сложность и больше времени на тренировку и предсказывание.

В следующем ниже примере исходного кода у нас три вызова метода `add()` на классе `Dense`. Метод `add()` добавляет слои в том же последовательном порядке, в котором мы их указали. Первый (позиционный) параметр – это число узлов, по 10 в первом и втором слоях и 1 в третьем слое. Обратите внимание, что в первом плотном (`Dense`) слое мы добавляем (именованный) параметр `input_shape`. Здесь мы определим входной вектор и соединим его с первым (входным) слоем в одной-единственной инстанции экземпляра плотного слоя:

```

from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense

model = Sequential()
model.add(Dense(10, input_shape=(13,)))
model.add(Dense(10))
model.add(Dense(1))

```

Для первого слоя в последовательной модели требуется параметр `input_shape`

Строит скрытый слой

Строит выходной слой как регрессор – одиночный узел

В качестве альтернативы слои можно определить в последовательном порядке как списковый параметр при инстанцировании класса `Sequential`:

```

from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense

model = Sequential([
    Dense(10, input_shape=(13,)),
    Dense(10),
    Dense(1)
])

```

Слои задаются в последовательном порядке в виде списка

Теперь давайте сделаем то же самое, но применим метод функционального API. Сначала мы создаем входной вектор путем инстанцирования класса `Input`. (Позиционный) параметр объекта `Input` – это форма входных данных, которая может быть вектором, матрицей либо тензором. В нашем примере у нас вектор длиной 13 элементов. И поэтому форма равна `(13,)`. Я уверен, что вы заметили концевую запятую. Она там находится, чтобы преодолеть одну причудливость Python. Без запятой `(13)` будет оцениваться как выражение: целочисленное значение 13, окруженное круглыми скобками. Добавленная запятая сообщает интерпретатору о том, что это кортеж (упорядоченное множество значений).

Далее мы создаем входной слой, инстанцируя библиотечный класс `Dense`. Позиционным параметром для объекта `Dense` является число узлов, которое в нашем примере равно 10. Обратите внимание на следующий специфический синтаксис: `(inputs)`. Класс `Dense` имеет тип `callable`; объект, возвращаемый при инстанцировании класса `Dense`, можно вызывать как функцию. Стало быть, мы вызываем его как функцию, и в этом случае функция принимает в качестве (позиционного) параметра входной вектор (или выходные данные слоя) для его подсоединения; следовательно, мы передаем ему `inputs`, чтобы входной вектор был привязан к 10-узловому входному слою.

Затем мы создаем скрытый слой, инстанцируя 10 узлами еще один объект `Dense`. Задействуя его свойство вызываемости, мы (полностью) связываем его с входным слоем.

Затем создаем выходной слой, инстанцируя одним узлом еще один объект `Dense`. Используя его в качестве вызываемого, мы (полностью) связываем его со скрытым слоем.

Наконец, мы собираем все это вместе, инстанцируя библиотечный класс `Model`, передав ему (позиционные) параметры для входного

вектора и выходного слоя. Помните, что все остальные слои между ними уже соединены, поэтому при инстанцировании объекта `Model()` их указывать не нужно:

```
from tensorflow.keras import Input, Model
from tensorflow.keras.layers import Dense
```

inputs = Input((13,)) ← Строит входной вектор (13 элементов)

input = Dense(10)(inputs) ← Строит первый (входной) слой (10 узлов) и соединяет его с входным вектором

hidden = Dense(10)(input) ← Строит следующий (скрытый) слой (10 узлов) и соединяет его с входным слоем

output = Dense(1)(hidden) ← Строит выходной слой (1 узел) и соединяет его с предыдущим (скрытым слоем)

model = Model(inputs, output) ← Строит нейронную сеть, указывая входной и выходной слои

2.1.8 Активационные функции

Во время тренировки или предсказания (посредством предсказательного вывода) каждый узел в слое будет выдавать значение узлам в следующем слое. Мы не хотим передавать значение как есть, но вместо этого иногда хотим изменять значение определенным образом. Этот процесс называется *активационной функцией*.

Подумайте о функции, которая возвращает результат, например `return result`. В случае активационной функции, вместо того чтобы возвращать `result`, мы возвращаем результат передачи результирующего значения в еще одну (активационную) функцию, например `return A(result)`, где `A()` – это активационная функция. В концептуальном плане об этом можно думать следующим образом:

```
def layer(params):
    """ внутри находятся узлы """
    result = некие_расчеты
    return A(result)

def A(result):
    """ модифицирует результат """
    return некое_модифицированное_значение_результата
```

Активационные функции помогают нейронным сетям учиться быстрее и лучше. Если активационная функция не указана, то по умолчанию значения с одного слоя передаются в следующий слой как есть (без изменений). Самая базовая активационная функция – это *шаговая функция*. Если значение больше 0, то выдается 1; в противном случае выдается 0. Шаговая функция не использовалась уже в течение очень долгого времени.

Давайте на мгновение остановимся и обсудим предназначение активационной функции. Вы, вероятно, слышали термин *нелинейность*. Что это такое? Для меня же важнее ответ на вопрос, что это *не* такое.

В традиционной статистике мы работали в низкоразмерном пространстве с сильной линейной корреляцией между входом и выходом.

дом. Эта корреляция может быть вычислена как полиномиальное преобразование входа, которое при преобразовании имеет линейную корреляцию с выходом. Наиболее фундаментальным примером является наклон линии, который представляется как $y = mx + b$. В данном случае x и y являются координатами линии, и мы хотим подобрать значение m , наклон и b , где линия пересекает ось y .

В глубоком обучении мы работаем в многомерном пространстве с существенной нелинейностью между входом и выходом. Эта нелинейность означает, что входы неравномерно соотносятся (не близко) с выходами, основываясь на полиномиальном преобразовании входов. Например, предположим, что налог на имущество составляет фиксированную процентную ставку (r) от стоимости дома. Налог на имущество может быть представлен функцией, которая умножает ставку на стоимость дома. Таким образом, мы имеем (прямо)линейную взаимосвязь между стоимостью (вход) и налогом на имущество (выход):

$$\text{налог} = f(\text{стоимость}) = r \times \text{стоимость}.$$

Давайте посмотрим на логарифмическую шкалу измерения землетрясений, в которой увеличение на 1 означает, что высвобождаемая мощность в 10 раз больше. Например, землетрясение силой 4 единицы в 10 раз сильнее, чем в 3 единицы. Применяя логарифмическое преобразование к входной мощности, мы получаем линейную взаимосвязь между мощностью и шкалой:

$$\text{шкала} = f(\text{мощность}) = \log(\text{мощность}).$$

В нелинейной взаимосвязи последовательности внутри входа имеют разные линейные взаимосвязи с выходом, и в глубоком обучении мы хотим усваивать точки отделимости, а также линейные функции для каждой входной последовательности. Например, возьмем возраст человека относительно дохода, чтобы продемонстрировать нелинейную взаимосвязь. В общем случае у малышей дохода нет, у детей начальной школы есть пособие, дети раннего подросткового возраста зарабатывают пособие плюс деньги за работу по дому, дети более позднего подросткового возраста зарабатывают деньги на работе, а затем, когда они поступают в колледж, их доход падает до нуля! После окончания колледжа их доход постепенно увеличивается вплоть до времени выхода на пенсию, когда он становится фиксированным. Мы могли бы смоделировать эту нелинейность в виде последовательностей по возрастам и усвоить линейную функцию для каждой последовательности, как показано ниже:

доход = $F1(\text{возраст}) = 0$	для возраста [0..5]
доход = $F2(\text{возраст}) = c1$	для возраста [6..9]
доход = $F3(\text{возраст}) = c1 + (w1 \times \text{возраст})$	для возраста [10..15]

доход = $F4(\text{возраст}) = (w_2 \times \text{возраст})$	для возраста [16..18]
доход = $F5(\text{возраст}) = 0$	для возраста [19..22]
доход = $F6(\text{возраст}) = (w_3 \times \text{возраст})$	для возраста [23..64]
доход = $F7(\text{возраст}) = c_2$	для возраста [65+]

Активационные функции помогают отыскивать нелинейные отделимости и соответствующую кластеризацию узлов внутри входных последовательностей, которые затем усваивают (почти) линейную взаимосвязь с выходом. В большинстве случаев вы будете использовать три активационные функции: выпрямленный линейный узел (rectified linear unit, аббр. ReLU), сигмоиду и софтмакс.

Мы начнем с ReLU, так как она используется наиболее часто во всех модельных слоях, кроме выходного. Сигмоидная и софтмаксная активации описаны в разделах 2.2 и 2.3. Изображенная на рис. 2.4 активация ReLU передает значения выше нуля, как есть (без изменений); в противном случае она передает ноль (сигнала нет).




Рис. 2.4 Функция для выпрямленного линейного узла отсекает все отрицательные значения до нуля. По сути, любое отрицательное значение равно отсутствию сигнала либо ~ нулю

ReLU обычно используется между слоями. В отличие от ранних исследователей, которые между слоями использовали разные активационные функции (такие как гиперболический тангенс), исследователи обнаружили, что ReLU дает наилучший результат в тренировке модели. В нашем примере мы добавим ReLU между каждым слоем:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense, ReLU

model = Sequential()
```

```

model.add(Dense(10, input_shape=(13,)))
model.add(ReLU())
model.add(Dense(10))
model.add(ReLU())
model.add(Dense(1))

```

По традиции принято добавлять активацию
в каждый невыходной слой

Давайте заглянем внутрь модельного объекта, чтобы увидеть, что мы построили именно то, что намеревались. Это можно сделать с помощью метода `summary()`. Указанный метод удобно использовать для визуализации построенных вами слоев и подтверждения, что построенное вами на самом деле соответствует тому, что вы намеревались построить. Он будет показывать сводную информацию в последовательном порядке по каждому слою:

```

model.summary()

```

Layer (type)	Output Shape	Param #
dense_56 (Dense)	(None, 10)	140
re_lu_18 (ReLU)	(None, 10)	0
dense_57 (Dense)	(None, 10)	110
re_lu_19 (ReLU)	(None, 10)	0
dense_58 (Dense)	(None, 1)	11

=====
 Total params: 261
 Trainable params: 261
 Non-trainable params: 0

В этом примере исходного кода вы видите, что сводка начинается с плотного слоя численностью 10 узлов (входной слой), за которым следует активационная функция ReLU, за которой следует второй плотный (скрытый) слой численностью 10 узлов, за которым следует активационная функция ReLU, и, наконец, за ним следует плотный (выходной) слой численностью 1 узел. Так что да, мы получили то, что ожидали.

Далее давайте посмотрим на поле параметров в сводке. Входной слой показывает 140 параметров. Как это число рассчитывается? У нас 13 входов и 10 узлов, так что 13×10 равно 130. Откуда берется 140? Каждое соединение между входами и каждым узлом имеет вес, что в сумме составляет 130. Но у каждого узла есть дополнительное смещение. А это 10 узлов, стало быть, $130 + 10 = 140$. Как я уже сказал, нейронная сеть будет «усваивать» веса и смещения во время тренировки. *Смещение* представляет собой усвоенный, или заученный, сдвиг, концептуально эквивалентный y -пересечению (b) в наклоне линии, где линия пересекает ось y :

$$y = b + mx.$$

В следующем (скрытом) слое вы видите 110 параметров. Это 10 выходов из входного слоя, соединенного с каждым из 10 узлов скрытого слоя (10×10), плюс 10 смещений для узлов в скрытых слоях, в общей сложности 110 подлежащих усвоению параметров.

2.1.9 Сокращенный синтаксис

Модуль TF.Keras предоставляет сокращенный синтаксис, применяющийся при указании слоев. На самом деле вам не нужно задавать отдельно активационные функции между слоями, как мы делали в предыдущем примере. Вместо этого активационную функцию можно задавать в качестве (именованного) параметра при создании экземпляра плотного (Dense) слоя.

Вы, возможно, спросите, почему бы не использовать сокращенный синтаксис всегда? Как вы увидите в главе 3, в современной модельной архитектуре активационной функции предшествует еще один промежуточный слой (пакетная нормализация) либо предшествует слою вообще (предактивационная пакетная нормализация). Следующий ниже пример исходного кода выполняет в точности то же самое, что и предыдущий:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense

model = Sequential()
model.add(Dense(10, input_shape=(13,), activation='relu'))
model.add(Dense(10, activation='relu'))
model.add(Dense(1))
```

Активационная функция задана
как именованный параметр в слое

Давайте вызовем метод `summary()` на этой модели:

```
model.summary()
```

Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 10)	140
dense_2 (Dense)	(None, 10)	110
dense_3 (Dense)	(None, 1)	11
Total params: 261		
Trainable params: 261		
Non-trainable params: 0		

Хм, и вы не увидите активаций между слоями, как в предыдущем примере. Почему так? Все дело в причудливости, с которой метод `summary()` выводит на экран результат. Они по-прежнему там.

2.1.10 Повышение точности с помощью оптимизатора

Завершив строительство порции сети, связанной с прямым распространением сигнала, как это было в нашем простом примере, для тренировки необходимо добавить несколько вещей. Это делается с помощью метода `compile()`. Указанный шаг добавляет выполняемое во время тренировки *обратное распространение*. Давайте дадим определение этому понятию и разведем его подробнее.

Всякий раз, когда мы отправляем данные (или пакет данных) по нейронной сети в прямом направлении, она вычисляет в предсказываемых результатах ошибки (именуемые *потерей*) или отклонение от фактических значений (именуемых *метками*) и использует эту информацию для поступательной корректировки весов и смещений узлов. Это и есть процесс тренировки модели.

Вычисление ошибки, как я уже сказал, называется вычислением *потери*. Ее можно вычислять многими способами. Поскольку сконструированный нами пример нейронной сети имеет вид *регрессора* (а значит, результат, цена дома, является действительной стоимостью), мы хотим использовать ту функцию потери, которая подходит для регрессора лучше всего. В нейронных сетях такого типа для расчета потери традиционно используется метод *среднеквадратической ошибки*. В Keras метод `compile()` принимает (именованный) параметр `loss`, используемый для указания метода расчета потери, который мы хотим применить. Мы собираемся передать ему значение `mse` (обозначающее среднеквадратическую ошибку, от англ. *mean square error*).

Следующим шагом в этом процессе является минимизирование потери с помощью оптимизатора; эта работа выполняется во время обратного распространения. Оптимизатор основан на *градиентном спуске*; при этом можно выбирать разные варианты алгоритма *градиентного спуска*. Эти термины бывает трудно понять с первого раза. По сути, всякий раз, когда мы пропускаем данные через нейронную сеть, мы используем рассчитанную потерю, чтобы решить, насколько сильно изменять веса и смещения в слоях. Цель – постепенно приближаться к правильным значениям весов и смещений, чтобы точно предсказывать или оценивать метку для каждого примера. Этот процесс поступательного приближения к точным значениям называется *схождением*. Задача оптимизатора состоит в том, чтобы рассчитать обновления весов, дабы поступательно приближаться к точным значениям и достичь схождения.

По мере того как потеря постепенно уменьшается, мы *сходимся*. После того как потеря выйдет на плато, у нас будет схождение. Результатом является точность нейронной сети. До использования градиентного спуска отыскание схождения на нетривиальной задаче при помощи методов, использовавшихся ранними исследователями ИИ, могло занимать годы вычислений на суперкомпьютере. После открытия применимости алгоритма градиентного спуска это время

было сокращено до дней, часов и даже нескольких минут в условиях обычной вычислительной мощности. Давайте перескажем через математику и просто скажем, что градиентный спуск – это волшебная пыль ученого, которая позволяет достигать хорошего локального оптимума.

В нашей регрессорной нейронной сети будет использоваться метод `rmsprop`¹:

```
model.compile(loss='mse', optimizer='rmsprop')
```

Теперь мы завершили создание первой тренируемой нейронной сети. Прежде чем приступить к подготовке данных и тренировке модели, мы рассмотрим еще несколько нейросетевых конструкций. В этих конструкциях используются две другие активационные функции, о которых я упоминал ранее: сигмоида и софтмакс.

2.2 Двоичный классификатор в форме глубокой нейронной сети

Еще одной формой глубокой нейронной сети является *двоичный классификатор*, т. н. *логистический классификатор*. Когда мы используем двоичный классификатор, мы хотим, чтобы нейронная сеть предсказывала, что входной сигнал чем-то является либо не является. Выходные данные могут иметь два состояния или класса: да/нет, истина/ложь, 0/1 и так далее.

Например, предположим, что у нас есть набор данных транзакций по кредитным картам, и каждая транзакция помечена как мошенническая либо немошенническая. Вспомните, что метка – это то, что мы хотим предсказывать.

В целом подход к конструированию, который мы к этому моменту усвоили, не меняется, за исключением активационной функции одно-узлового выходного слоя и метода оптимизации/потери. Вместо *линейной* активационной функции на выходном узле, как для регрессора, мы будем использовать *сигмоидную* активационную функцию. Сигмоида сплюсчивает все значения так, что они укладываются между 0 и 1, как показано на рис. 2.5. По мере того как значения движутся прочь от центра, они быстро движутся к экстремумам 0 и 1 (асимптотам).

Теперь мы будем кодировать ее в двух стилях, которые обсуждали. Давайте начнем с предыдущего примера исходного кода, в котором мы указываем активационную функцию в качестве (именованного) параметра. В данном примере мы добавляем в выходной плотный (*Dense*) слой параметр `activation='sigmoid'`, чтобы пропустить выходной результат из финального узла через сигмоидную функцию.

¹ То есть распространение корня квадратного из среднеквадратической ошибки, от англ. *root mean square propagation*. – Прим. перев.




Рис. 2.5 График функции для сигмоиды

Затем мы меняем наш параметр потери на `binary_crossentropy`. Эта функция потери обычно используется в двоичном классификаторе:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense

model = Sequential()
model.add(Dense(10, input_shape=(13,), activation='relu'))
model.add(Dense(10, activation='relu'))
model.add(Dense(1, activation='sigmoid'))
model.compile(loss='binary_crossentropy',
              optimizer='rmsprop',
              metrics=['accuracy'])
```

Сигмоида используется для двоичной классификации

По традиции для двоичной классификации принято использовать потерю и оптимизатор

Не все активационные функции имеют свой собственный класс, как ReLU. Это еще одна причудливость в модуле TF.Keras. Вместо него любая поддерживаемая активация создается классом под названием `Activation`. Параметром является предопределенное имя активационной функции. В нашем примере `relu` относится к выпрямленному линейному узлу, а `sigmoid` – к сигмоиде. Следующий ниже исходный код выполняет те же действия, что и приведенный выше:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense, Activation

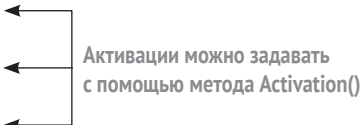
model = Sequential()
model.add(Dense(10, input_shape=(13,)))
```

```

model.add(Activation('relu'))
model.add(Dense(10))
model.add(Activation('relu'))
model.add(Dense(1))
model.add(Activation('sigmoid'))

model.compile(loss='binary_crossentropy',
              optimizer='rmsprop',
              metrics=['accuracy'])

```



Активации можно задавать с помощью метода `Activation()`

Теперь мы перепишем тот же исходный код, используя подход функционального API. Обратите внимание, что мы неоднократно использовали переменную `x`. Это общепринятая практика. Мы хотим избежать создания большого числа одноразовых переменных. Поскольку мы знаем, что в нейронных сетях такого типа выход из каждого слоя является входом в следующий слой (или активацию), за исключением входа и выхода, мы используем `x` постоянно в качестве соединяющей переменной.

К этому месту в книге вы должны уже более-менее освоиться с этими двумя подходами:

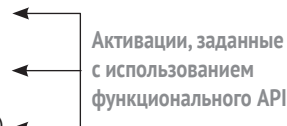
```

from tensorflow.keras import Model, Input
from tensorflow.keras.layers import Dense, ReLU, Activation

inputs = Input((13,))
x = Dense(10)(inputs)
x = Activation('relu')(x)
x = Dense(10)(x)
x = Activation('relu')(x)
x = Dense(1)(x)
output = Activation('sigmoid')(x)
model = Model(inputs, output)

model.compile(loss='binary_crossentropy',
              optimizer='rmsprop',
              metrics=['accuracy'])

```



Активации, заданные с использованием функционального API

2.3 Мультиклассовый классификатор в форме глубокой нейронной сети

Допустим, у нас есть набор антропометрических показателей (к примеру, рост и вес) и пол, который ассоциирован с каждым набором этих показателей, и мы хотим предсказывать, является ли некто новорожденным, малышом, предподростком, подростком или взрослым. Мы хотим, чтобы наша модель классифицировала или предсказывала более чем из одного класса или метки – в данном примере у нас в сумме пять классов возрастных категорий. Для этой задачи можно использовать еще одну форму глубокой нейронной сети, именуемую *мультиклассовым классификатором*.

Мы уже видим, что у нас будут некоторые осложнения. Например, мужчины во взрослом возрасте в среднем выше женщин. Но в пред-подростковом возрасте девочки преимущественно выше мальчиков. Мы знаем, что в среднем мужчины становятся тяжелее в раннем взрослом возрасте по сравнению с подростковым возрастом, но женщины в среднем становятся тяжелее с меньшей вероятностью. Поэтому мы должны предвидеть проблемы с предсказыванием примерно в предподростковом возрасте для девочек, подростковом возрасте для мальчиков и взрослом возрасте для женщин.

Эти проблемы являются примерами нелинейности; взаимосвязь между признаком и предсказанием не является линейной. Напротив, взаимосвязь может быть разбита на сегменты разрозненной линейности. И с таким типом задач нейронные сети справляются очень хорошо.

Давайте добавим четвертый показатель – площадь поверхности носа. Исследования, подобные взятому из *анналов пластической хирургии* (<https://pubmed.ncbi.nlm.nih.gov/3579170/>), показали, что как у девочек, так и у мальчиков площадь поверхности носа продолжает расти в возрасте от 6 до 18 лет и, по существу, останавливается в 18 лет.

Таким образом, теперь у нас есть четыре признака и метка, состоящая из пяти классов. В следующем ниже примере мы изменим размер входного вектора на 4, чтобы соответствовать числу признаков, и изменим размер выходного слоя на 5 узлов, чтобы соответствовать числу классов. В этом случае каждый выходной узел соответствует одному уникальному классу (новорожденный, малыш и т. д.). Мы хотим натренировать нейронную сеть так, чтобы каждый выходной узел выдавал в качестве предсказания значение от 0 до 1. Например, 0.75 будет означать, что узел на 75 % уверен в том, что предсказание является соответствующим классом.

Каждый выходной узел будет самостоятельно учиться и предсказывать свою уверенность в том, что входное значение является соответствующим классом. Однако этот процесс приводит к проблеме: поскольку значения независимы, они не будут составлять в сумме 1 (100 %). Именно здесь полезна функция *софтмакс*. Эта математическая функция будет брать множество значений (выходы из выходного слоя) и сплющивать их в диапазон от 0 до 1, а также будет гарантировать, что все значения будут в сумме составлять 1. Идеально. Благодаря ей мы можем брать выходной узел с наибольшим значением и говорить, какое предсказание было сделано, и одновременно сообщать соответствующий этому предсказанию уровень уверенности. Таким образом, если наибольшее значение равно 0.97, то мы можем сказать, что нашему предсказанию соответствует уверенность на уровне 97 %.

На рис. 2.6 представлена диаграмма мультиклассовой модели. В этом примере выходной слой имеет два узла, каждый из которых соответствует предсказыванию другого класса. Каждый узел дела-

ет независимое предсказание того, насколько сильно он верит, что входное значение является соответствующим классом. Затем два независимых предсказания пропускаются через софтмаксную активацию, которая сплюсчивает значения, чтобы они в сумме составляли 1 (100 %). В данном примере один класс предсказан на 97%-ном, а другой – на 3%-ном уровнях уверенности.

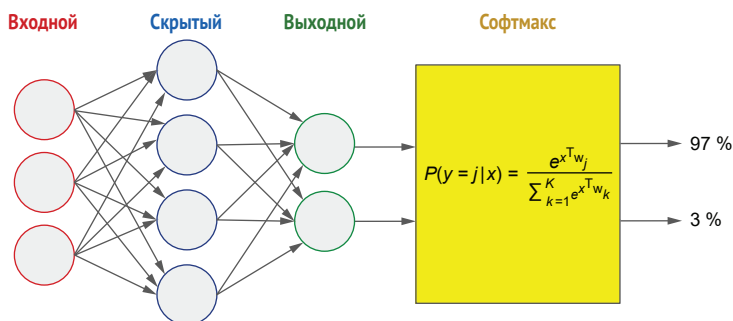


Рис. 2.6 Добавление софтмаксной активации в выходной слой для мультиклассового классификатора помогает повышать уровень уверенности, соответствующий модельному предсказанию

Следующий ниже исходный код показывает пример строительства мультиклассового классификатора в форме глубокой нейронной сети. Мы начинаем с организации наших входного и выходного слоев соответственно с несколькими признаками и несколькими классами. Затем мы заменяем сигмоидную активационную функцию на софтмаксную. Потом задаем функцию потерь как категориальную перекрестную энтропию (`categorical_crossentropy`). Она традиционно рекомендуется для мультиклассовой классификации чаще всего. Мы не будем углубляться в статистические величины в основе перекрестной энтропии, кроме того что перекрестная энтропия вычисляет потерю из нескольких распределений вероятностей. В двоичном классификаторе мы имеем два распределения вероятностей и используем вычисление двоичной перекрестной энтропии (`binary_crossentropy`); а в мультиклассовом классификаторе, чтобы вычислять потери из нескольких (более двух) распределений вероятностей, мы используем категориальную перекрестную энтропию.

Наконец, будем использовать популярный и широко используемый вариант градиентного спуска, именуемый оптимизатором *Adam* (`adam`). Указанный оптимизатор включает в себя несколько аспектов других методов, таких как *rmsprop* (распространение корня квадратного из среднеквадратической ошибки) и *adagrad* (адаптивный градиент), а также адаптивную скорость усвоения. Обычно он считается лучшим в своем классе оптимизатором, предназначенным для широкого спектра нейронных сетей:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense
```

```
model = Sequential()
model.add(Dense(10, input_shape=(4,), activation='relu'))
model.add(Dense(10, activation='relu'))
model.add(Dense(5, activation='softmax'))
```

```
model.compile(loss='categorical_crossentropy',
              optimizer='adam',
              metrics=['accuracy'])
```

Входной слой для входной
формы 1-мерного вектора
из четырех признаков

В выходном слое softmaxная
активация используется
для мультиклассового
классификатора

По традиции для мультиклассового классификатора
принято использовать функцию потерь и оптимизатор

2.4 Мультиметочный мультиклассовый классификатор в форме глубокой нейронной сети

Теперь давайте обратимся к предсказыванию двух или более классов (меток) на вход. Воспользуемся предыдущим примером предсказания, что некто является новорожденным, малышом, ребенком, подростком, подростком или взрослым. На этот раз мы удалим пол как один из признаков и вместо этого сделаем его одной из меток, которую будем предсказывать. Нашими входами будут рост, вес и площадь поверхности носа, а нашими выходами будут два класса: возрастная категория (новорожденный, малыш и т. д.) и пол (мужчина или женщина). Пример предсказания мог бы выглядеть следующим образом:

[рост, вес, площадь поверхности носа] – > нейронная сеть ->
[подросток, женского пола]

Для того чтобы предсказывать две или более меток из нескольких входных значений, как мы делаем здесь, мы используем – как вы уже поняли – *мультиметочный мультиклассовый классификатор*. Для этого нам нужно внести в предыдущий мультиклассовый классификатор несколько изменений. Число выходных классов в выходном слое равно сумме всех выходных категорий. В данном случае раньше у нас их было пять, а теперь мы добавляем еще два для пола, в общей сложности семь. Мы также хотим трактовать каждый выходной класс как двоичный классификатор, и, стало быть, нам нужен ответ типа «да/нет», поэтому мы меняем активационную функцию на сигмоиду. Для инструкции компиляции мы имитируем то, что делали с более простыми глубокими нейросетями в этой главе, и задаем функцию потерь как `binary_crossentropy`, а оптимизатор как `rmsprop`. Ниже приведена имплементация каждого шага:

```

from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense

model = Sequential()
model.add(Dense(10, input_shape=(3,), activation='relu'))
model.add(Dense(10, activation='relu'))
model.add(Dense(7, activation='sigmoid'))

model.compile(loss='binary_crossentropy',
              optimizer='rmsprop',
              metrics=['accuracy'])

```

Входной вектор – это просто рост, вес и площадь поверхности носа

И возрастные демографические, и гендерные категории объединены в один классификатор

Использует сигмоидную активацию с функцией потери `binary_crossentropy`, чтобы предсказывать каждый класс независимо как 0 либо 1 или близко к ним

Заметили ли вы потенциальную проблему в этой конструкции? Давайте допустим, что мы выдаем два класса (метки) с самыми высокими значениями (от 0 до 1); то есть наиболее уверенные предсказания. Что делать, если в результате нейронная сеть с высокой уверенностью предсказывает и подростка, и подростка, а также с меньшей уверенностью и мужской пол, и женский пол? Ну, мы можем исправить эту ситуацию с помощью некоторой постлогики, выбирая наивысшую уверенность из первых пяти выходных классов (возрастную демографию) и наивысшую уверенность из последних двух классов (пол). Другими словами, мы делим семь выходных классов на две соответствующие категории и из каждой категории выбираем выход с наивысшим уровнем уверенности.

Функциональный API дает нам возможность исправить это без добавления какой-либо постлогики. В данном случае мы хотим заменить выходной слой, который объединяет два набора классов, двумя параллельными выходными слоями, один для первого набора классов (возрастные категории) и один для второго набора классов (пол). Такая организация показана на рис. 2.7.

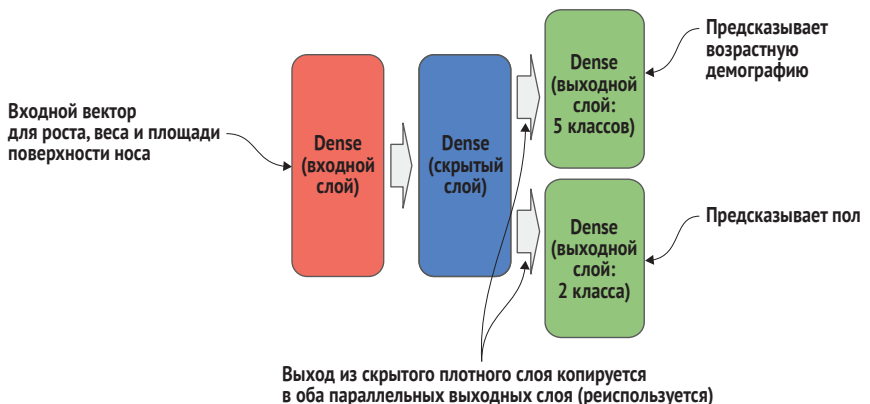


Рис. 2.7 Выходные слои мультиметочного мультиклассификатора с двумя параллельными выходными слоями

Приведенный ниже пример исходного кода отличается от предыдущего листинга исходного кода только в финальном выходном слое. Вместо одного выходного слоя здесь мы имеем два параллельных слоя.

Затем, когда с помощью класса `Model` мы все сводим вместе, вместо того чтобы передавать один выходной слой, мы передаем список выходных слоев: `[output1, output2]`. Наконец, поскольку каждый выходной слой делает независимые предсказания, мы можем вернуться к их трактовке как *мультиклассового классификатора* – и, стало быть, мы возвращаемся к использованию `categorical_crossentropy` в качестве функции потери и `adam` в качестве оптимизатора.

Такая конструкция мультиметочного мультиклассификатора также называется *нейронной сетью с множественным выходом* – в ней каждый выход усваивает отличающуюся задачу. Поскольку мы будем тренировать эту модель делать несколько независимых предсказаний, такая сеть также называется *многозадачной* моделью:

```
from tensorflow.keras import Input, Model
from tensorflow.keras.layers import Dense

inputs = Input((3,))
x = Dense(10, activation='relu')(inputs)
x = Dense(10, activation='relu')(x)
output1 = Dense(5, activation='softmax')(x)
output2 = Dense(2, activation='softmax')(x)
model = Model(inputs, [output1, output2])

model.compile(loss='categorical_crossentropy',
              optimizer='adam',
              metrics=['accuracy'])
```

Каждая из двух категорий имеет отдельный выходной слой и получает копию того же самого входа

Итак, какая же конструкция является правильной (или лучше) для мультиметочного мультиклассового классификатора? Все зависит от приложения. Если все классы относятся к одной категории, например возрастной демографии, то используйте первый шаблон, единственную задачу. Если классы принадлежат к разным категориям, таким как возрастная демография и пол, то используйте второй шаблон – многозадачность. В данном примере мы используем шаблон многозадачности, потому что на выходе хотим усваивать две категории.

2.5 Простой классификатор изображений

Вы знаете базовые типы глубоких нейронных сетей и как их кодировать с помощью `TF.Keras`. А теперь давайте построим нашу первую простую модель для классифицирования изображений.

Нейронные сети используются для классифицирования изображений в компьютерном зрении вдоль и поперек. Давайте начнем

с основ. Для малых полутоновых изображений, как показано на рис. 2.8, можно использовать глубокую нейросеть, аналогичную той, которую мы уже описывали для мультиклассового классификатора, служащего для предсказания возрастной демографии. Этот тип глубокой нейросети получил широкое распространение с использованием модифицированного набора данных Национального института стандартов и технологии (MNIST), служащего для распознавания рукописных цифр. Указанный набор состоит из полутоновых изображений размером 28×28 пикселей. Каждый пиксел представлен целочисленным значением от 0 до 255 (0 – черный, 255 – белый, а значения между ними – оттенки серого).




Рис. 2.8 Матричное представление полутонового изображения

Однако нам нужно внести одно изменение. Полутоновое изображение представлено матрицей (2-мерным массивом). Вообразите матрицу в виде решетки размером высота \times ширина, где ширина – это столбцы, а высота – строки. Однако глубокая нейросеть на входе принимает *вектор*, то есть 1-мерный массив. И что же тогда делать? Можно *разгладить* двумерную матрицу в одномерный вектор.

2.5.1 Разглаживание

Мы собираемся выполнять классификацию, трактуя каждый пиксел как признак. Используя пример набора данных MNIST, изображения 28×28 будут иметь 784 пиксела и, следовательно, 784 признака. Мы конвертируем матрицу (2-мерную) в вектор (1-одномерный) путем ее разглаживания.

Разглаживание – это процесс размещения каждой строки в вектор в последовательном порядке. Таким образом, вектор начинается с первого ряда пикселей, за которым следует второй ряд пикселей, и продолжается, заканчивая последним рядом пикселей. На рис. 2.9 показано разглаживание матрицы в вектор.

Возможно, в этот момент вы спросите, зачем нужно разглаживать 2-мерную матрицу в 1-мерный вектор? Это связано с тем, что

в глубокой нейросети входом в плотный слой должен быть 1-мерный вектор. В следующей главе, когда мы представим сверточные нейронные сети, вы увидите примеры сверточных слоев, которые принимают 2-мерный вход.



Рис. 2.9 Матрица, разглаженная в вектор

В приведенном ниже примере мы добавляем слой в начале нейронной сети, чтобы разгладить входное значение, используя библиотечный класс `Flatten`. Остальные слои и активации являются типичными для набора данных MNIST. Обратите внимание, что входной формой для объекта `Flatten` является 2-мерная форма (28, 28). Выходом из этого объекта будет 1-мерная форма (784,):

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense, Flatten, ReLU, Activation

model = Sequential()
model.add(Flatten(input_shape=(28,28)))
model.add(Dense(512, activation='relu'))
model.add(Dense(512, activation='relu'))
model.add(Dense(10, activation='softmax'))
model.compile(loss='categorical_crossentropy',
              optimizer='adam',
              metrics=['accuracy'])
```

Двумерное полутоновое изображение разглаживается в 1-мерный вектор для подачи в глубокую нейросеть

MNIST обычно выполняется как входной слой и один скрытый плотный слой с численностью узлов между 128, 256 и 512 узлами

Теперь давайте воспользуемся методом `summary()` и посмотрим на слои. Как видно из сводки, первый слой является разглаженным слоем и показывает, что на выходе из слоя будет 784 узла. Это то, чего мы и хотим. Также обратите внимание на число параметров, которые сеть должна будет усвоить во время тренировки, почти 700 000:

```
model.summary()
```

Layer (type)	Output Shape	Param #
flatten_1 (Flatten)	(None, 784)	0
dense_69 (Dense)	(None, 512)	401920
re_lu_20 (ReLU)	(None, 512)	0
dense_70 (Dense)	(None, 512)	262656
re_lu_21 (ReLU)	(None, 512)	0
dense_71 (Dense)	(None, 10)	5130
activation_10 (Activation)	(None, 10)	0

```
=====
Total params: 669,706
Trainable params: 669,706
Non-trainable params: 0
```

2.5.2 Переподгонка и отсев

Во время тренировки набор данных разбивается на тренировочные данные и тестовые данные (также именуемые отложенными данными). При этом во время тренировки нейронной сети используются только тренировочные данные. После того как нейронная сеть достигнет схождения, которое мы подробно обсудим в главе 4, тренировка прекращается, как показано на рис. 2.10.




Рис. 2.10 Схождение происходит, когда наклон потери выходит на плато

После этого, в целях получения точности модели на тренировочных данных, тренировочные данные снова распространяются по сети в прямом направлении без активирования обратного распространения, и поэтому усвоения не происходит. Этот порядок работы также называется выполнением натренированной нейронной сети в *режиме предсказательного вывода* или *режиме предсказания*. В разбивке на тренировочный/тестовый наборы данных тестовые данные, которые были отложены в сторону и не использовались как часть тренировки, снова распространяются в прямом направлении по сети без активирования обратного распространения с целью получения точности.

Почему мы разбиваем данные на части и изымаем тестовые данные из тренировки, откладывая их в сторону? В идеале точность на тренировочных и тестовых данных будет почти одинаковой. На самом же деле точность на тестовых данных всегда будет немного меньше. И для этого есть причина.

После того как вы достигнете схождения, непрерывное пропускание тренировочных данных через нейронную сеть приведет к тому, что нейроны будут все больше и больше запоминать тренировочные

образцы в ущерб обобщению на образцы, которые она ни разу не видела во время тренировки. Это состояние называется *переподгонкой*. Когда нейронная сеть переподогнана под тренировочные данные, вы будете получать высокую точность на тренировочных данных, но существенно более низкую точность на тестовых/оценочных данных.

Даже без тренировки после схождения у вас будет некоторая переподгонка. Вполне возможно, что набор данных/задача имеют нелинейность (собственно, поэтому вы и используете нейронную сеть). В силу этого отдельные нейроны будут сходиться с неодинаковой скоростью. При измерении схождения вы смотрите на систему в совокупности. До этого некоторые нейроны уже сошлись, и продолжение тренировки приведет к их переподгонке. Вот почему точность на тестовых/оценочных данных всегда будет, по крайней мере, немного меньше точности на тренировочных данных.

В целях урегулирования проблемы переподгонки, возникающей во время тренировки нейронных сетей, можно использовать *регуляризацию*. Она добавляет небольшой объем случайного шума во время тренировки, чтобы не давать модели запоминать образцы и повышать ее способность обобщать на незнакомые образцы после тренировки модели.

Самый базовый тип регуляризации называется *отсевом*. Отсев – это как забывание. Когда мы учим маленьких детей, мы задействуем механическое запоминание, к примеру когда мы просим их запомнить таблицу умножения чисел с 1 по 12. Мы заставляем их повторять пары снова и снова до тех пор, пока они не будут произносить правильный ответ в любом порядке в 100 % случаев. Но если мы спросим их: «Сколько будет 13 на 13?» – то они, скорее всего, уставят на нас пустой взгляд. На данный момент таблица умножения в их памяти переподогнана. Ответ на каждую пару умножения, образцы, запрограммирован в ячейках памяти мозга, и у них нет никакого способа передать эти знания за пределы диапазона от 1 до 12.

Когда дети становятся старше, мы переключаемся на абстрагирование. Вместо того чтобы учить ребенка запоминать ответы, мы учим их вычислять ответ, хотя они и могут допускать ошибки в расчетах. Во время этой второй фазы обучения некоторые нейроны, связанные с механическим запоминанием, погибнут. Сочетание гибели этих нейронов (что означает забывание) и абстрагирования позволяет мозгу ребенка обобщать и теперь решать произвольные задачи на умножение, хотя иногда они и будут ошибаться, даже в таблице умножения 12×12 , с некоторым вероятностным распределением.

Техника отсева в нейронных сетях имитирует этот процесс перехода к абстрагированию и усвоению с вероятностным распределением неопределенности. Слой отсева можно добавлять между любым слоем, при этом вы указываете процент узлов (от 0 до 1), которые нужно забыть. Сами узлы отсеяны не будут, но вместо этого на каждой прямой передаче во время тренировки случайная подборка узлов не будет передавать сигнал в прямом направлении. Сигнал от случайно

отобранного узла будет забыт. Так, например, если указать отсев 50 % (0.5), то при каждой прямой подаче данных случайная подборка половины узлов не будет посылать сигнал.

Преимущество здесь состоит в том, что мы минимизируем эффект локализованной переподгонки, непрерывно тренируя нейронную сеть для совокупного схождения. На практике традиционно принято устанавливать значения отсева между 20 % и 50 %.

В следующем ниже примере исходного кода мы добавили в входной и скрытые слои 50%-ный отсев. Обратите внимание, что мы разместили его перед активационной функцией (ReLU). Поскольку отсев будет приводить к тому, что сигнал от отсеянного узла будет равен нулю, уже не важно, в какое место добавлять слой Dropout, до либо после активационной функции:


```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense, Flatten, ReLU, Activation, Dropout

model = Sequential()
model.add(Flatten(input_shape=(28,28)))
model.add(Dense(512))
model.add(Dropout(0.5))
model.add(ReLU())

model.add(Dense(512))
model.add(Dropout(0.5))
model.add(ReLU())

model.add(Dense(10))
model.add(Activation('softmax'))

model.compile(loss='categorical_crossentropy',
              optimizer='adam',
              metrics=['accuracy'])
```



Отсев добавлен в целях предотвращения переподгонки

Резюме

- Вход и входной слой нейронной сети – это не одно и то же, и они не обязательно должны иметь одинаковый размер. На вход подаются признаки образцов, тогда как входной слой – это первый слой весов и смещений, который учится предсказывать соответствующую метку.
- Между входным и выходным слоями глубокая нейронная сеть имеет один или несколько слоев, которые называются скрытыми слоями. Используя функцию программирования в качестве аналогии, входной слой – это параметры функции, выходной слой – возвращаемое значение функции, а скрытые слои – это программный код внутри функции, который преобразовывает входные параметры в выходное возвращаемое значение.

- Нейронные сети представляют собой ориентированные ациклические графы, в которых данные передаются в прямом направлении от входного слоя к выходному слою.
- Активации, такие как ReLU и софтмакс, сплющивают выходные сигналы слоев. Согласно данным исследователей, эти активации помогают моделям лучше учиться.
- Роль оптимизатора заключается в обновлении весов с учетом потери текущего пакета данных, чтобы потери в последующих пакетах становились меньше.
- Регрессор использует линейную активацию для предсказания непрерывного действительного значения, например для предсказания продажной цены дома.
- Двоичный классификатор использует сигмоидную активацию для предсказания двоичного состояния: истина/ложь, 1/0, да/нет.
- Мультиклассовый классификатор использует софтмаксную активацию для предсказания класса из набора классов, например для предсказания возрастной демографии человека.
- Последовательный API прост в освоении, но ограничен тем, что он не поддерживает в модели ветвление.
- Функциональный API предпочтительнее последовательного API для производственных моделей.
- Переподгонка происходит, когда модель запоминает тренировочные образцы во время тренировки, что не позволяет модели делать обобщения на образцы, на которых она не тренировалась. Методы регуляризации вносят малый объем случайного шума во время тренировки, что показало свою эффективность в предотвращении запоминания.

Сверточная и остаточная нейронные сети

Эта глава охватывает следующие ниже темы:

- понимание структуры сверточных нейронных сетей;
- строительство модели в форме ConvNet;
- конструирование и строительство модели в форме VGG;
- конструирование и строительство модели в форме остаточной сети.

В главе 2 представлены основы глубоких нейронных сетей, сетевая архитектура, основанная на плотных слоях. Мы также продемонстрировали, как делать простой классификатор изображений с использованием плотных слоев, и обсудили ограничения при попытке масштабировать глубокую нейросеть до более крупных размеров изображений. Внедрение нейронных сетей с применением сверточных слоев для выделения и усвоения признаков, именуемых *сверточными нейронными сетями* (convolutional neural network, аббр. CNN), позволило масштабировать классификаторы изображений для практических применений.

В этой главе рассматриваются шаблоны конструирования и эволюция шаблонов конструирования ранних некогда передовых сверточных нейронных сетей. Здесь мы рассмотрим три шаблона конструирования в их эволюционной последовательности:

- ConvNet;
- VGG;
- остаточные сети.

Каждый из этих шаблонов конструирования внес свой вклад в современные конструкции сверточных нейронных сетей сегодняшнего дня. Архитектура ConvNet, а в качестве более раннего примера AlexNet, ввела шаблон поочередного выделения признаков и редукции размерности посредством сведения¹ и последовательного увеличения числа фильтров по мере углубления в слои. Архитектура VGG ввела группировку сверток в блоки по одной или несколько сверток, откладывая редукцию размерности со сведением до конца блока. Архитектура остаточных сетей ввела дополнительную группировку блоков в группы, откладывая редукцию размерности до конца группы и используя сведение признаков, а также сведение для редукции, еще ввела концепцию разветвленных путей – отождествляющая связь – с целью реиспользования признаков между блоками.

3.1 Сверточные нейронные сети

Ранние сверточные нейронные сети – это нейронные сети, которые традиционно состоят из двух частей: внешней и внутренней. Внутренняя часть – это глубокая нейросеть, которую мы уже рассмотрели. Название *сверточная нейронная сеть* происходит от внешней части, именуемой *сверточным слоем*. Внешняя часть – сверточная нейросеть – действует как препроцессор. Внутренняя часть – глубокая нейросеть – выполняет *классификационное усвоение*. Внешняя часть предобрабатывает данные изображения, сводя их к виду, вычислительно практичному для глубокой нейросети, чтобы на ней учиться. Предназначение внешней части в форме сверточной нейросети – *усвоение признаков*.

На рис. 3.1 изображена сверточная нейросеть, в которой сверточные слои действуют как внешняя часть для усвоения признаков из изображения, которые затем передаются во внутреннюю глубокую нейросеть для классифицирования признаков.

В этом разделе описываются базовые шаги и компоненты, применявшиеся в сборке этих более ранних сверточных нейросетей. Хотя мы специально не освещаем сеть AlexNet, ее успех в качестве победителя конкурса ILSVCR 2012 года в области классифицирования изображений можно считать катализатором для исследователей в разведывании и разработке сверточных конструкций. Принципы сборки и внешней части AlexNet были включены в самый ранний шаблон конструирования, ConvNet, для практического применения.

¹ Сведение (pooling), или концентрирование, пулинг, – это поступательная редукция пространственного размера представления с целью сокращения числа параметров и вычислений в нейросети. Сведение выполняется на основе функций максимума (максимальное сведение), минимума (минимальное сведение), среднего (среднее сведение) и прочих статистических функций. – *Прим. перев.*

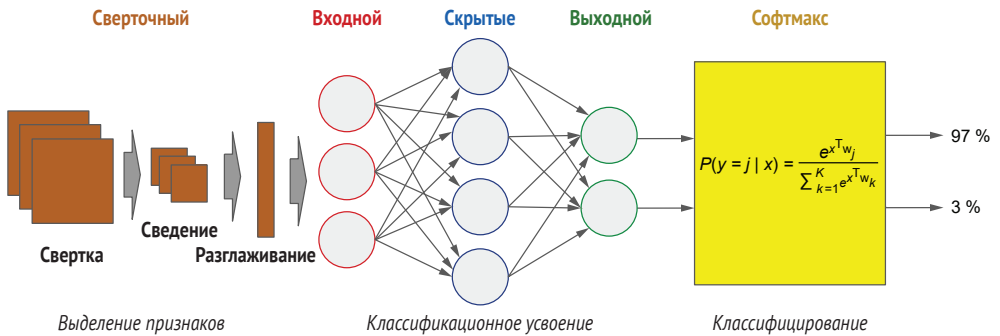


Рис. 3.1 Свертка действует для глубокой нейронной сети как внешняя часть с целью усвоения признаков, а не пикселей

3.1.1 Зачем для моделирования изображений использовать сверточную нейросеть поверх глубокой нейросети

Как только мы достигаем крупных размеров изображений, число пикселей в глубокой нейросети начинает обходиться вычислительно слишком дорого, чтобы осуществлять на практике. Предположим, у вас есть изображение размером 1 Мб, в котором каждый пиксел представлен одним байтом (значением в интервале 0..255). При 1 Мб у вас будет 1 млн пикселей. Для этого размера потребуется входной вектор из 1 млн элементов. И давайте допустим, что входной слой имеет 1024 узла. Только в одном входном слое число обновляемых и усваиваемых весов будет превышать миллиард (1 млн × 1024)! Хлоп. И мы снова сидим у суперкомпьютера с вычислениями продолжительностью в жизнь.

Давайте сравним это с нашим примером MNIST из главы 2, состоящим из 784 пикселей × 512 узлов во входном слое. Это 400 000 усваиваемых весов, что значительно меньше, чем 1 млрд. Первое вы можете сделать на своем ноутбуке, но не посмеете попробовать второе.

В следующих далее подразделах мы рассмотрим компоненты сверточных нейросетей и решение ими проблемы того, что в противном случае было бы вычислительным нецелесообразным числом весов, т. н. *параметров*, для классифицирования изображений.

3.1.2 Отбор с пониженной частотой (изменение размера)

В целях решения проблемы слишком большого числа параметров один из подходов состоял в уменьшении разрешающей способности изображения с помощью процесса, именуемого *даунсэмплинг*, или *отбор с пониженной частотой*¹. Но если уменьшать разрешающую

¹ Для справки: термин *отбор с пониженной частотой* (downsampling) в обработке цифровых сигналов еще называется понижением частоты или плотности выборки, децимацией или сжатием. – Прим. перев.

способность изображения слишком сильно, то в какой-то момент мы потеряем способность четко различать то, что находится на изображении; оно станет размытым и/или будет содержать артефакты. Таким образом, первый шаг состоял в уменьшении разрешающей способности до уровня, при котором у нас все еще будет достаточно подробностей.

По традиции для повседневного компьютерного зрения принято использовать около 224×224 пикселей. Мы делаем это путем изменения размера. Даже при такой низкой разрешающей способности и трех каналах для цветных изображений и входном слое численностью 1024 узла у нас по-прежнему будет 154 млн обновляемых и усваиваемых весов ($224 \times 224 \times 3 \times 1024$); см. рис. 3.2.



Рис. 3.2 Число параметров во входном слое до и после изменения размера (источник изображения: Pixabay, Stockvault)

Таким образом, до введения сверточных слоев тренировка на реальных изображениях была недоступной для нейронных сетей. Мы начнем с того, что сверточный слой представляет собой внешнюю часть нейронной сети, которая преобразовывает изображения из высокоразмерного пиксельного представления в существенно более низкоразмерное признаковое представление. Тогда вектором, подаваемым на вход в глубокую нейросеть, могут становиться существенно более низкоразмерные признаки. Таким образом, сверточная внешняя часть – это часть между данными изображения и глубокой нейросетью.

Но давайте предположим, что мы имеем достаточную вычислительную мощность, чтобы использовать только глубокую нейросеть и усваивать 154 млн весов во входном слое, как в нашем предыдущем примере. Тогда нужно учесть, что пиксели очень сильно зависят от позиции во входном слое. И вот мы учимся распознавать кота на левой стороне картинки. Но затем мы сдвигаем кота в середину картинки. Сейчас нам нужно научиться распознавать кота из нового набора позиций пикселей – ого! Теперь переместим его вправо, добавим кота, в лежачей позе, прыгающего в воздухе и так далее.

Процесс распознавания изображения с различных ракурсов называется *трансляционной инвариантностью*. Для базовых 2-мерных визуализаций, таких как цифры и буквы, это работает (методом грубой силы), но для всего остального это не работает. Ранние исследования показали, что при разглаживании начального изображения в 1-мерный вектор теряется пространственная взаимосвязь признаков, которые составляют классифицируемый объект, такой как кот. Даже если вы успешно натренировали глубокую нейросеть распознавать, скажем, кота по пикселям в середине изображения, эта глубокая нейросеть вряд ли распознает объект, если он будет на изображении сдвинут.

Далее мы обсудим тему сверток, а именно вопрос о том, как свертки решили эту проблему путем усваивания признаков, а не пикселей, при этом удерживая 2-мерную форму для пространственных взаимосвязей.

3.1.3 Обнаружение признаков

Вместо классифицирования позиций пикселей этих более высоко-разрешающих и более сложных изображений мы выполняем их распознавание путем обнаружения и классифицирования признаков. Визуализируйте в уме изображение и задайтесь вопросом, что заставляет вас распознавать то, что там есть. Выйдите за рамки высокоуровневого вопроса типа «это человек, кот или здание?» и спросите себя, почему вы можете отличить человека от здания, перед которым он стоит, или отделить человека от кота, которого он держит. Ваши глаза распознают низкоуровневые признаки, такие как края, размытость и контрастность.

Как показано на рис. 3.3, эти низкоуровневые признаки собираются в контуры, а затем в пространственные взаимосвязи. Внезапно глаз/мозг обретает способность распознавать нос, уши, глаза – и воспринимать, что это морда кота или лицо человека.

В компьютере *сверточный слой* выполняет задачу обнаружения признаков внутри изображений. Каждая свертка состоит из набора фильтров. Эти фильтры представляют собой $N \times M$ -матрицы значений, которые используются для обнаружения возможного присутствия признаков. Думайте о них как о маленьких окошках. Они скользят по изображению, и в каждом месте выполняется сравнение между фильтром и пиксельными значениями в этом месте. Это сравнение выполняется с помощью матричного точечного произведения, но здесь мы статистику пропустим. Важно то, что в результате этой операции будет сгенерировано значение, указывающее на силу, с которой в этом месте на изображении был обнаружен признак. Например, значение 4 будет указывать на более сильное присутствие признака, чем значение 1.

До появления нейронных сетей исследователи в области обработки изображений конструировали эти фильтры вручную. Сегодня

фильтры вместе с весами нейронной сети усваиваются автоматически. В сверточном слое мы указываем размер фильтра и число фильтров. Типичными являются размеры фильтров 3×3 и 5×5 , причем размер 3×3 является наиболее распространенным. Число фильтров варьируется больше, но обычно оно кратно 16, к примеру 16, 32 или 64 для неглубоких сверточных нейросетей и 256, 512 и 1024 для глубоких сверточных нейросетей.




Рис. 3.3 Поток распознавания низкоуровневых признаков вплоть до высокоуровневых признаков человеческим глазом

В дополнение к этому мы указываем *сдвиговой шаг*, то есть темп, с которым фильтр скользит по изображению. Например, если шаг равен 1, то фильтр продвигается на 1 пиксел за раз; отсюда фильтр 3×3 будет частично накладываться на предыдущий шаг (и, следовательно, то же самое будет и с шагом 2). Шаг 3 наложения не имеет. На практике чаще всего используются шаги 1 и 2. Каждый усваиваемый фильтр порождает карту признаков, то есть попарное соотношение, показывающее силу, с которой в том или ином месте на изображении был обнаружен признак, как видно на рис. 3.4.

Фильтр может остановиться, когда дойдет до края изображения, либо продолжиться до тех пор, пока не будет покрыт последний столбец, как показано на рис. 3.5. Первый случай называется *без дополнения*. Последний случай называется *с дополнением*. Когда фильтр выходит частично за край, мы хотим дать этим воображаемым пикселям значение. Типичными значениями являются zero или same (то же самое) – то же самое, как в последнем столбце.

Когда у вас несколько сверточных слоев, на практике традиционно принято поддерживать одинаковое число либо увеличивать число фильтров в более глубоких слоях, а также использовать шаг 1 в пер-

вом слое и шаг 2 в более глубоких слоях. Увеличение числа фильтров позволяет переходить от обнаружения грубых признаков к обнаружению более детальных признаков внутри грубых. Увеличение шага компенсирует увеличение размера удерживаемых данных; этот процесс называется *сведением признаков* (feature pooling), при котором происходит отбор с пониженной частотой из карт признаков.




Рис. 3.4 Фильтр скользит по изображению и порождает признаковую карту обнаруженных признаков

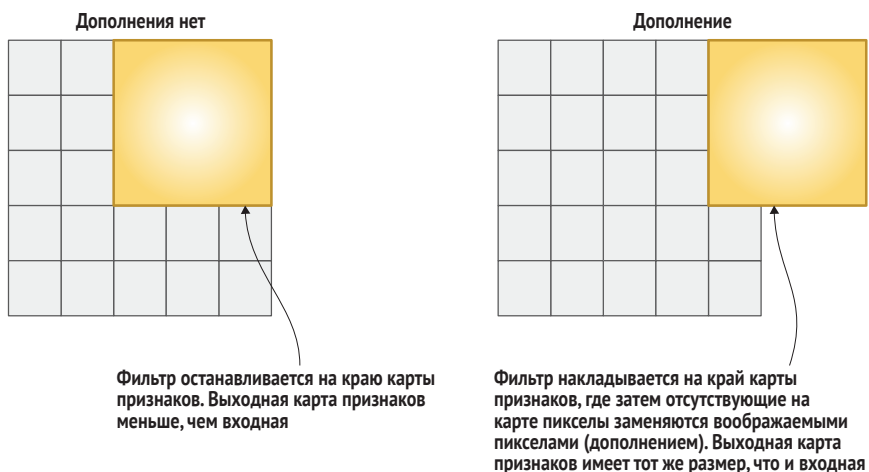


Рис. 3.5 Место остановки фильтра зависит от дополнения

В сверточных нейросетях используются два типа отбора с пониженной частотой (или понижения разрешающей способности): собственно *сведение* и *сведение признаков*. При сведении используется фиксированный алгоритм отбора с пониженной частотой из данных изображения. При сведении признаков наилучший алгоритм отбора с пониженной частотой из конкретного набора данных усваивается автоматически:

Больше фильтров => Больше данных
Более крупные шаги => Меньше данных

Далее мы рассмотрим процедуру сведения подробнее. К процедуре сведения признаков мы обратимся в разделе 3.2.

3.1.4 Сведение

Несмотря на то что каждая генерируемая карта признаков обычно равна размеру изображения или меньше его, суммарный объем данных увеличивается, поскольку мы генерируем несколько карт признаков (например, 16). Хлоп! И следующим шагом придется сокращать суммарный объем данных при удержании обнаруженных признаков и соответствующих пространственных взаимосвязей между обнаруженными признаками.

Как я уже сказал, этот шаг есть, и он называется *сведением*; это то же самое, что и *отбор с пониженной частотой* (либо *прореживание*). В этой процедуре размерность карт признаков сокращается с использованием либо максимума пикселей (отбор с пониженной частотой), либо их среднего значения (прореживание) внутри карты признаков. При сведении, как показано на рис. 3.6, мы задаем размер сводимой области в виде матрицы $N \times M$, а также шаг. На практике традиционно принято использовать сведение размером 2×2 с шагом 2. Это приводит к сокращению пиксельных данных на 75 % при сохранении достаточной разрешающей способности, для того чтобы обнаруженные признаки не были потеряны.

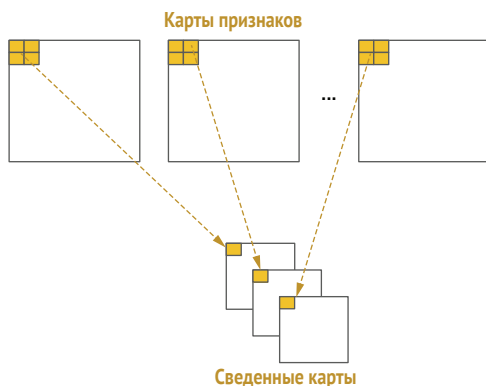


Рис. 3.6 Сведение изменяет карты признаков в сторону меньшей размерности

Сведение можно трактовать и иным образом, в контексте прироста информации. Сокращая число нежелательных или менее информативных пикселей (например, на заднем плане), мы уменьшаем энтропию и делаем оставшиеся пиксели информативнее.

3.1.5 Разглаживание

Вспомните, что глубокие нейронные сети на входе принимают векторы – одномерные массивы чисел. В случае сведенных карт мы имеем список (множество) 2-мерных матриц, поэтому нам нужно преобразовать их в один 1-мерный вектор, который затем становится входным вектором для глубокой нейросети. Этот процесс называется разглаживанием: мы разглаживаем список 2-мерных матриц в один 1-мерный вектор.

Это довольно просто. Мы начинаем с первой строки первой сведенной карты, которая становится началом 1-мерного вектора. Затем берем вторую строку и добавляем ее в конец, потом третью строку и так далее. Далее мы переходим ко второй сведенной карте и делаем то же самое, непрерывно добавляя каждую строку до тех пор, пока не завершим последнюю сведенную карту. Если следовать одинаковой последовательности сведенных карт, то пространственные взаимосвязи между обнаруженными признаками будут сохраняться на всех изображениях для проведения тренировки и *предсказательного вывода* (предсказания), как показано на рис. 3.7.

Например, если у нас 16 сведенных карт размером 20×20 и три канала в расчете на сведенную карту (например, каналы RGB в цветном изображении), то размер 1-мерного вектора составит $16 \times 20 \times 20 \times 3 = 19\,200$ элементов.

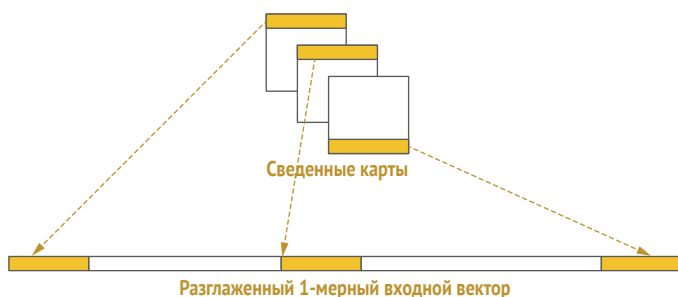


Рис. 3.7 При разглаживании сведенных карт пространственные взаимосвязи сохраняются

3.2 Конструкция в форме ConvNet для сверточной нейросети

Теперь давайте приступим к работе с TF.Keras. Возьмем гипотетическую ситуацию, но которая похожа на сегодняшний реальный мир. Приложение вашей компании поддерживает человеко-машинный интерфейс, и в настоящее время к нему можно обращаться с помощью голосовой активации. Вам была поручена задача про-

демонстрировать, как доказательство концепции, расширение человеко-машинного интерфейса за счет включения языка жестов в соответствии с федеральными законами о доступности для людей с ограниченными возможностями. Соответствующий закон, раздел 503 Закона о реабилитации 1973 года, «запрещает федеральным подрядчикам и субподрядчикам проводить дискриминацию при приеме на работу в отношении лиц с ограниченными возможностями и требует от работодателей принятия позитивных мер по рекрутированию, найму, продвижению по службе и удержанию этих лиц» (<https://www.dol.gov/agencies/ofccp/section-503>).

Чего вам не следует делать, так это допускать, что вы сможете натренировать модель, используя произвольные помеченные изображения языка жестов и методику обогащения изображений. Данные, их подготовка и конструкция модели должны соответствовать системе, фактически развернутой «в дикой природе». В противном случае, помимо неутешительной точности, модель, возможно, будет усваивать шум, который будет подставлять ее под ложноположительные результаты, что в итоге может привести к неожиданным последствиям и сделать ее уязвимой для взлома. В главе 12 эта тема рассматривается подробнее.

В нашем доказательстве концепции мы собираемся показать распознавание знаков руки только для букв английского алфавита (от А до Z). Кроме того, мы исходим из того, что человек будет подавать знаки непосредственно перед камерой с прямого ракурса. Мы не хотим, чтобы модель усваивала, например, этническую принадлежность сигнализирующего лица. Так что по этой и другим причинам цвет не имеет значения.

Для того чтобы наша модель не усваивала цвет (шум), мы будем тренировать ее в полутонном режиме. Мы сконструируем модель для процесса усвоения и предсказания, т. н. *предсказательного вывода*, в оттенках серого. Мы хотим, чтобы модель усваивала контуры руки. Мы разработаем модель в двух частях: внешнюю часть в форме сверточной нейросети и внутреннюю часть в форме глубокой нейросети, как показано на рис. 3.8.

Следующий ниже пример исходного кода написан методом последовательного API и в длинной форме; активационные функции задаются с использованием соответствующего метода (вместо указания их в качестве параметра при добавлении соответствующего слоя).

Мы начнем с добавления сверточного слоя численностью 16 фильтров в качестве первого слоя с использованием библиотечного класса `Conv2D`. Вспомните, что число фильтров равно числу генерируемых карт признаков (в данном случае 16). Размер каждого фильтра будет составлять 3×3 , который задается параметром `kernel_size` (размер ядра), а шаг 2 – параметром `strides`.

Обратите внимание, что для параметра `strides` вместо одного значения 2 указывается кортеж (2, 2). Первая цифра – это горизонтальный шаг (поперек), а вторая цифра – вертикальный шаг (вниз). По традиции

принято использовать одинаковые горизонтальное и вертикальное значения; поэтому вместо «шаг 2×2» мы обычно говорим «шаг 2».

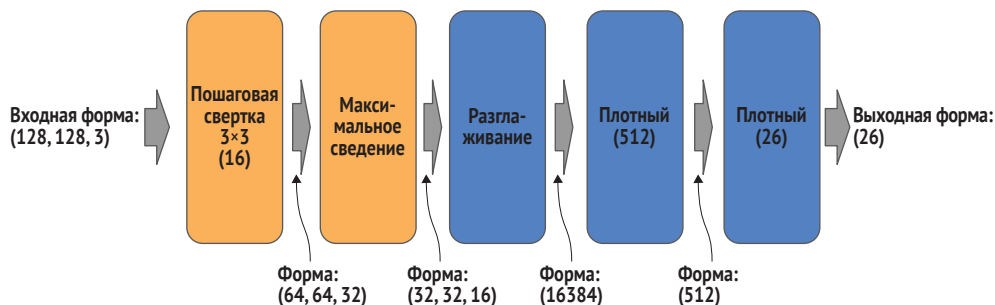


Рис. 3.8 Сеть ConvNet со сверточной внешней частью и глубокой внутренней частью

Вы, возможно, спросите, что означает часть 2D в названии Conv2D? 2D означает, что на вход сверточного слоя будет поступать стопка матриц (т. е. двумерный массив). В этой главе мы будем придерживаться 2-мерных сверток, использование которых традиционно принято в практике компьютерного зрения.

Давайте рассчитаем выходной размер этого слоя. Как вы помните, при шаге 1 каждая выходная карта признаков будет иметь тот же размер, что и изображение. С 16 фильтрами она будет в 16 раз больше данных на входе. Но так как мы использовали шаг 2 (сведение признаков), каждая карта признаков будет сокращена на 75 %, поэтому суммарный размер выхода будет в 4 раза больше входа.

Данные на выходе из сверточного слоя затем пропускаются через активационную функцию ReLU и потом передаются в слой максимального сведения, используя библиотечный класс `MaxPool2D`. Размер участка сведения составит 2×2, как указано в параметре `pool_size`, с шагом 2 согласно параметру `strides`. Слой сведения сократит карты признаков на 75 % до сведенных карт признаков.

Давайте рассчитаем выходной размер после слоя сведения. Мы знаем, что размер при поступлении в 4 раза превышает входной. При дополнительном сокращении на 75 % выходной размер будет таким же, как и входной. Так чего же мы здесь добились? Во-первых, мы натренировали набор фильтров усваивать первый набор грубых признаков (что приводит к приросту информации), исключили незначительную пиксельную информацию (сократив энтропию) и усвоили наилучший метод сокращения карт признаков. Хм, кажется, мы многого добились.

Сведенные карты признаков затем разглаживаются с помощью библиотечного класса `Flatten` в 1-мерный вектор для подачи на вход в глубокую нейросеть. Взглянем на параметр `padding`. Для наших целей достаточно сказать, что почти во всех случаях вы будете использовать значение `same`; просто значение по умолчанию равно `valid`, и поэтому вам нужно добавлять это значение в явной форме.

Наконец, мы подбираем для наших изображений входной размер. Нам нравится сокращать размер до максимально меньшего, не теряя при этом возможности обнаруживать признаки, необходимые для распознавания контуров руки. В данном случае мы выбираем 128×128 . Класс `Conv2D` имеет особенность: при указании данных в оттенках серого он всегда требует задавать число каналов вместо того, чтобы по умолчанию иметь значение 1; поэтому вместо $(128, 128)$ мы указали $(128, 128, 1)$.

Соответствующий исходный код приведен ниже:

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, ReLU, Activation
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten

model = Sequential()
model.add(Conv2D(16, kernel_size=(3, 3), strides=(2, 2), padding="same",
                 input_shape=(128, 128, 1)))
model.add(ReLU())
model.add(MaxPooling2D(pool_size=(2, 2), strides=(2, 2)))
model.add(Flatten())
model.add(Dense(512))
model.add(ReLU())
model.add(Dense(26))
model.add(Activation('softmax'))
model.compile(loss='categorical_crossentropy',
              optimizer='adam',
              metrics=['accuracy'])
```

← Перед выходным слоем 2-мерные карты признаков разглаживаются в 1-мерный вектор

← Размер карт признаков сокращается путем сведения

← Данные изображения подаются на вход сверточного слоя

Давайте посмотрим на детали слоев нашей модели с помощью метода `summary()`:

Выходом из сверточного слоя являются 16 карт признаков в виде 2-мерных массивов размера 64×64

Выход из слоя сведения сокращает размеры карт признаков до 32×32

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 64, 64, 16)	160
re_lu_1 (ReLU)	(None, 64, 64, 16)	0
max_pooling2d_1 (MaxPooling2D)	(None, 32, 32, 16)	0
flatten_1 (Flatten)	(None, 16384)	0
dense_1 (Dense)	(None, 512)	8389120
re_lu_2 (ReLU)	(None, 512)	0

Число параметров для 512-узлового плотного слоя составляет более 8 млн; каждый узел в слое разглаживания соединен с каждым узлом в плотном слое

dense_2 (Dense)	(None, 26)	13338
activation_1 (Activation)	(None, 26)	0
=====		
Total params: 8,402,618		
Trainable params: 8,402,618		
Non-trainable params: 0		

Последний плотный слой имеет 26 узлов, по одному для каждой буквы в английском алфавите

Вот как следует читать столбец выходной формы (Output Shape). Для входного слоя Conv2D выходная форма показывает (None, 64, 64, 16). Первое значение в кортеже – это число примеров (размер пакета), которые будут пропускаться через сеть в одной прямой задаче. Поскольку оно определяется во время тренировки, для него установлено значение None, указывая на то, что оно будет привязано, когда данные будут поданы в модель. Последнее число – это число фильтров, которое мы установили равным 16. Два числа посередине (64, 64) – это выходной размер карт признаков – в данном случае 64×64 пиксела каждая (в общей сложности 16). Выходной размер определяется размером фильтра (3×3), шагом (2×2) и дополнением (same). Указанная нами комбинация приведет к сокращению высоты и ширины вдвое, что уменьшит размер в общей сложности на 75 %.

Для слоя MaxPooling2D выходной размер сведенных карт признаков равен 32×32. При указании участка сведения 2×2 и шага 2 высота и ширина сведенных карт признаков будут сокращены вдвое, что уменьшит размер в общей сложности на 75 %.

Разглаженный выход из сведенных карт признаков представляет собой 1-мерный вектор размером 16 384, рассчитанный как $16 \times (32 \times 32)$. Давайте посмотрим, соответствует ли это тому, что мы рассчитали ранее, что выходной размер карт признаков должен совпадать с входным размером. Наш вход имеет размер 128×128, то есть 16 384, что соответствует выходному размеру из слоя Flatten.

Каждый элемент (пиксел) в разглаженных сведенных картах признаков подается в каждый узел входного слоя глубокой нейросети, который имеет 512 узлов. Таким образом, число соединений между разглаженным слоем и входным слоем составляет $16\,384 \times 512 \approx 8.4$ млн. Это число весов, которое подлежит усвоению в этом слое, где будет происходить большая часть вычислений (в подавляющем объеме).

Теперь давайте покажем тот же самый пример исходного кода в вариации последовательного стиля. Здесь активационные методы задаются с помощью параметра activation в каждой инстанцииции слоя (таких как Conv2D(), Dense()):

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense

from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten
```

```

model = Sequential()

model.add(Conv2D(16, kernel_size=(3, 3), strides=(2, 2), padding="same",
                activation='relu', input_shape=(128,128, 1)))
model.add(MaxPooling2D(pool_size=(2, 2), strides=(2, 2)))
model.add(Flatten())

model.add(Dense(512, activation='relu'))
model.add(Dense(26, activation='softmax'))

model.compile(loss='categorical_crossentropy',
              optimizer='adam',
              metrics=['accuracy'])

```

Теперь давайте покажем тот же пример исходного кода третьим способом, используя метод функционального API. В этом подходе мы определяем каждый слой по отдельности, начиная с входного вектора и переходя к выходному слою. В каждом слое мы используем полиморфизм для вызова инстанцированного класса (слоя) в качестве вызываемого объекта и передаем объект предыдущего слоя для соединения с ним.

Например, при обращении к первому плотному (Dense) слою как вызываемому объекту мы передаем в виде параметра слоевой объект Flatten. Поскольку он является вызываемым объектом, это приведет к полному соединению слоя Flatten и первого плотного слоя (каждый узел в слое Flatten будет соединен с каждым узлом в слое Dense):

```

from tensorflow.keras import Input, Model
from tensorflow.keras.layers import Dense
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten

inputs = Input(shape=(128, 128, 1))
layer = Conv2D(16, kernel_size=(3, 3), strides=(2, 2), padding="same",
              activation='relu')(inputs)
layer = MaxPooling2D(pool_size=(2, 2), strides=(2, 2))(layer)
layer = Flatten()(layer)
layer = Dense(512, activation='relu')(layer)
outputs = Dense(26, activation='softmax')(layer)

model = Model(inputs, outputs)

```

В сверточном слое требуется указать число каналов во входном векторе

Строит сверточный слой

Сокращает размер карт признаков путем сведения

3.3 Сети в форме VGG

Сверточные нейронные сети типа VGG были разработаны Группой по визуальной геометрии в Оксфорде. Этот тип сетей был разработан для участия в международном конкурсе ILSVRC по распознаванию изображений из 1000 классов изображений. Архитектура VGGNet заняла в конкурсе 2014 года первое место в задаче определения местоположения изображения и второе место в задаче классифицирования изображений.

В то время как AlexNet (и соответствующий ему шаблон конструирования ConvNet) считается дедушкой сверточных сетей, VGGNet (и соответствующий ему шаблон конструирования VGG) считается отцом формализации шаблона конструирования на основе групп сверток. Как и его предшественники в AlexNet, он продолжал рассматривать сверточные слои как внешнюю часть нейросети и держал крупную внутреннюю часть в форме глубокой нейросети для классификационной задачи. Основопологающие принципы, лежащие в основе шаблона конструирования VGG, таковы:

- группирование нескольких сверток в блоки, с одинаковым числом фильтров;
- поступательное удвоение числа фильтров в блоках;
- откладывание сведения до конца блока.

При обсуждении шаблона конструирования VGG в современном контексте может возникнуть первоначальная путаница в отношении терминов «группа» и «блок». В своих исследованиях по VGGNet авторы использовали термин «сверточная группа». Впоследствии исследователи переработали группировочные шаблоны в сверточные группы, состоящие из сверточных блоков. В сегодняшней номенклатуре группа VGG называлась бы блоком.

Этот шаблон сконструирован с использованием нескольких принципов, которые легко усвоить. Сверточная внешняя часть состоит из последовательности пар (и позже троек) сверток одинакового размера, за которыми следует максимальное сведение. Слой максимального сведения сокращает размер сгенерированных карт признаков на 75 %, а следующая пара (или тройка) сверточных слоев затем удваивает число усвоенных фильтров. Принцип, лежащий в основе конструкции свертки, заключался в том, что ранние слои усваивают грубые признаки, а последующие слои, путем увеличения числа фильтров, усваивают все более и более детализированные признаки, и максимальное сведение используется между слоями с целью минимизирования роста размера (и впоследствии усваиваемых параметров) карт признаков. Наконец, внутренняя часть в форме глубокой нейросети состоит из двух одинаковых по размеру плотных скрытых слоев по 4096 узлов каждый и финального плотного выходного слоя из 1000 узлов для классифицирования. На рис. 3.9 показаны первые сверточные группы в архитектуре VGG.

Наиболее известными версиями указанной нейросети являются VGG 16 и VGG 19. Архитектуры VGG 16 и VGG 19, которые использовались в конкурсе, вместе с их тренировочными весами с конкурса были опубликованы в открытом доступе. Поскольку они очень часто применялись в переносе обучения (трансферном обучении), другие разработчики сохраняли сверточную внешнюю часть преднатренированных на ImageNet сетей VGG16 или VGG19 и соответствующие веса и прикрепляли новую внутреннюю глубокую нейросеть для перетренировки под новые классы изображений. На рис. 3.10 изображена архитектурная схема сети VGG16.




Рис. 3.9 В архитектуре VGG свертки сгруппированы, и сведение откладывается до конца группы




Рис. 3.10 Архитектура VGG16 состоит из сверточной внешней части, составленной из групп VGG, за которой следует внутренняя часть в форме глубокой нейросети

Итак, давайте продолжим и запрограммируем VGG16 в двух стилях кодирования: первый в последовательном потоке и второй процедурно с использованием *реиспользуемых* функций с целью дублирования общих блоков слоев и параметров, предназначенных для их конкретных настроек. Мы также заменим указание параметров `kernel_size` и `pool_size` в качестве именованных и вместо этого укажем их в качестве позиционных:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense
```

```
model = Sequential()

model.add(Conv2D(64, (3, 3), strides=(1, 1), padding="same",
                  activation="relu", input_shape=(224, 224, 3)))
model.add(Conv2D(64, (3, 3), strides=(1, 1), padding="same",
                  activation="relu"))
model.add(MaxPooling2D((2, 2), strides=(2, 2)))

model.add(Conv2D(128, (3, 3), strides=(1, 1), padding="same",
                  activation="relu"))
model.add(Conv2D(128, (3, 3), strides=(1, 1), padding="same",
                  activation="relu"))
model.add(MaxPooling2D((2, 2), strides=(2, 2)))

model.add(Conv2D(256, (3, 3), strides=(1, 1), padding="same",
                  activation="relu"))
model.add(Conv2D(256, (3, 3), strides=(1, 1), padding="same",
```

Первый сверточный блок

Второй сверточный блок – удвоение числа фильтров

Третий сверточный блок – удвоение числа фильтров

```

        activation="relu"))
model.add(Conv2D(256, (3, 3), strides=(1, 1), padding="same",
        activation="relu"))
model.add(MaxPooling2D((2, 2), strides=(2, 2)))
model.add(Conv2D(512, (3, 3), strides=(1, 1), padding="same",
        activation="relu"))
model.add(Conv2D(512, (3, 3), strides=(1, 1), padding="same",
        activation="relu"))
model.add(Conv2D(512, (3, 3), strides=(1, 1), padding="same",
        activation="relu"))
model.add(MaxPooling2D((2, 2), strides=(2, 2)))
model.add(Conv2D(512, (3, 3), strides=(1, 1), padding="same",
        activation="relu"))
model.add(Conv2D(512, (3, 3), strides=(1, 1), padding="same",
        activation="relu"))
model.add(Conv2D(512, (3, 3), strides=(1, 1), padding="same",
        activation="relu"))
model.add(MaxPooling2D((2, 2), strides=(2, 2)))

model.add(Flatten())
model.add(Dense(4096, activation='relu'))
model.add(Dense(4096, activation='relu'))

model.add(Dense(1000, activation='softmax'))
model.compile(loss='categorical_crossentropy',
        optimizer='adam',
        metrics=['accuracy'])

```

Четвертый сверточный блок – удвоение числа фильтров

Пятый (последний) сверточный блок

Внутренняя часть в форме глубокой нейросети

Выходной слой для классифицирования (1000 классов)

Вы только что закодировали шаблон VGG16 – замечательно. А теперь давайте запрограммируем то же самое, используя стиль процедурного реиспользования. В этом примере мы создаем процедуру (функцию) `conv_block()`, которая строит сверточные блоки и принимает в качестве параметров число слоев в блоке (2 либо 3) и число фильтров (64, 128, 256 либо 512). Обратите внимание, что мы держим первый сверточный слой за пределами процедуры `conv_block`. Для первого слоя необходим параметр `input_shape`. Мы могли бы закодировать его как флаг для `conv_block`, но поскольку это будет происходить всего один раз, это не будет реиспользованием. И поэтому мы будем его использовать внутрискриптно:

```

from tensorflow.keras import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense

def conv_block(n_layers, n_filters):
    """
    n_layers : number of convolutional layers
    n_filters: number of filters
    """
    for n in range(n_layers):
        model.add(Conv2D(n_filters, (3, 3), strides=(1, 1), padding="same",

```

Сверточный блок, имплементированный как процедура

```

        activation="relu"))
model.add(MaxPooling2D(2, strides=2))

model = Sequential()
model.add(Conv2D(64, (3, 3), strides=(1, 1), padding="same",
    activation="relu",
    input_shape=(224, 224, 3))) ← Первый сверточный блок
                                задается отдельно, поскольку
                                он требует наличия параметра
                                input_shape
conv_block(1, 64) ← Второй
conv_block(2, 128) ← по пятый
conv_block(3, 256) ← сверточные
conv_block(3, 512) ← блоки
conv_block(3, 512)

model.add(Flatten())
model.add(Dense(4096, activation='relu'))

model.add(Dense(4096, activation='relu'))

model.add(Dense(1000, activation='softmax'))

model.compile(loss='categorical_crossentropy',
    optimizer='adam',
    metrics=['accuracy'])

```

Попробуйте выполнить метод `model.summary()` в обоих примерах, и вы увидите, что выходы идентичны.

3.4 Сети в форме ResNet

Сверточные нейронные сети в форме ResNet (остаточной сети) были разработаны в Microsoft Research для участия в международном конкурсе ILSVRC. Сеть ResNet в конкурсе 2015 года заняла первое место во всех категориях конкурса ImageNet и Common Objects in Context (аббр. COCO, Распространенные объекты в контексте).

Описанный в предыдущем разделе шаблон конструирования VGGNet имел ограничения по глубине, на которую модельная архитектура могла уходить в слои вниз, прежде чем начинать страдать от исчезающих и взрывающихся (стремительно растущих) градиентов. Кроме того, разные слои, сходящиеся с разной скоростью, могли приводить к расхождению во время тренировки.

Исследователи компонента шаблона конструирования в форме остаточных блоков остаточной сети предложили новое соединение между слоями, которое они назвали *отождествляющей связью*¹. Отождествляющая связь ввела самую раннюю концепцию реиспользования признаков. До отождествляющей связи каждый сверточный

¹ Отождествляющая связь (identity link), или связь через тождество, – это прямая связь с применением укороченного перехода на основе тождественного преобразования, $h(x) = x$. – Прим перев.

блок выполнял выделение признаков на предыдущем сверточном выходе, не владея никакими знаниями из предыдущих выходных данных. Отождествляющую связь можно трактовать как состыковку между текущим и предыдущим сверточными выходами для реиспользования признаковой информации, полученной из более ранних выделений признаков. Конкурентно с ResNet другие исследователи – например, в Google, с Inception v1 (GoogLeNet) – дополнительно детализировали шаблоны сверточного конструирования в группы и блоки. Параллельно с этими конструктивными улучшениями была введена пакетная нормализация.

Использование отождествляющих связей наряду с пакетной нормализацией обеспечило более высокую стабильность между слоями, уменьшив как исчезающие, так и взрывающиеся градиенты и расхождения между слоями, позволяя модельной архитектуре углубляться в слои с целью повышения точности предсказания.

3.4.1 Архитектура

В ResNet и других архитектурах этого класса используются разные шаблоны соединений между слоями. В шаблонах, которые мы обсуждали ранее (ConvNet и VGG), используется полносвязный шаблон «слой к слою».

Архитектура ResNet34 представила соответственно новый блочный слой и шаблон соединения слоев, остаточные блоки и отождествляющее соединение. Остаточный блок в ResNet34 состоит из блоков двух идентичных сверточных слоев без слоя сведения. Каждый блок имеет отождествляющее соединение, которое создает параллельный путь между входом в остаточный блок и выходом из него, как показано на рис. 3.11. Как и в VGG, каждый последующий блок удваивает число фильтров. Сведение выполняется в конце последовательности блоков.

Одна из проблем с нейронными сетями заключается в том, что по мере добавления более глубоких слоев (при условии повышения точности) их результативность может деградировать. Она может становиться не лучше, а хуже. И это происходит по нескольким причинам. По мере углубления мы добавляем больше параметров (весов). Чем больше параметров, тем больше мест, в которых каждое входное значение в тренировочных данных будет вписываться под избыточные параметры. Вместо того чтобы обобщать, нейронная сеть будет просто усваивать каждый тренировочный пример (используя механическое запоминание). Другая проблема заключается в *ковариатном сдвиге*: по мере того как мы будем углубляться, распределение весов будет расширяться (распространяться дальше друг от друга), в результате чего нейронной сети будет сложнее сходиться. Первый случай приводит к деградации результативности на тестовых (отложенных) данных, а второй – на тренировочных данных, а также к исчезновению или взрыву градиента.

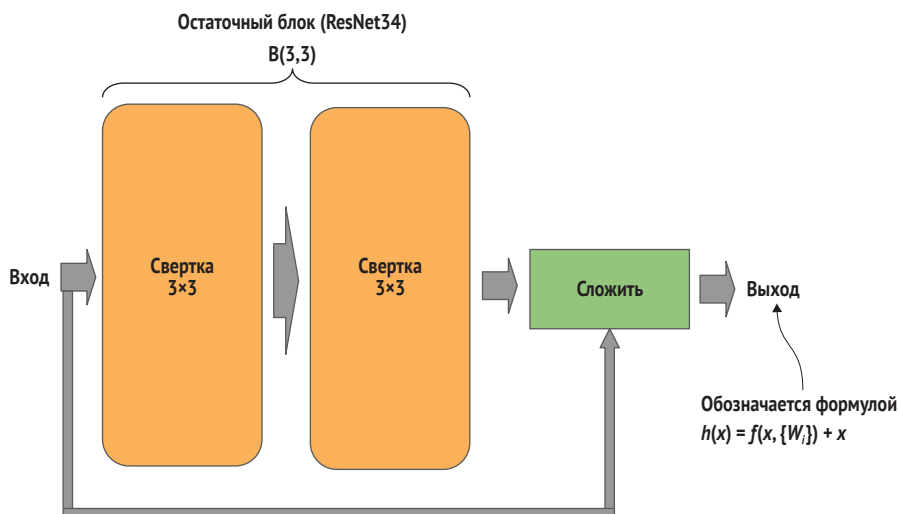


Рис. 3.11 Остаточный блок, в котором вход представляет собой матрицу, добавляемую в выход свертки

Остаточные блоки позволяют строить нейронные сети с более глубокими слоями без деградации результативности на тестовых данных. Блок ResNet можно рассматривать как блок VGG с добавлением отождествляющей связи. В то время как блок в стиле VGG выполняет обнаружение признаков, отождествляющая связь удерживает входные данные для последующего блока, в результате чего вход в следующий блок состоит из обнаружения предыдущих признаков и из их входных данных.

Удерживая информацию из прошлого (предыдущий вход), эта блочная конструкция позволяет нейронным сетям проникать глубже, чем визави в форме VGG, с повышением точности. VGG и ResNet можно представить математически следующим образом. В обоих случаях мы хотим усвоить формулу $h(x)$, то есть распределение (например, меток) тестовых данных. В случае VGG мы усваиваем функцию $f(x, \{W\})$, где $\{W\}$ представляет веса. В случае ResNet это уравнение модифицируется добавлением члена « $+x$ », то есть тождества:

$$\text{VGG: } h(x) = f(x, \{W\})$$

$$\text{ResNet: } h(x) = f(x, \{W\}) + x$$

Следующий ниже фрагмент исходного кода показывает то, как остаточный блок можно закодировать в TF.Keras с использованием метода функционального API. Переменная x представляет выход из слоя, являясь входом в следующий слой. В начале блока мы удерживаем копию выходных данных из предыдущего блока/слоя в качестве переменной `shortcut`. Затем пропускаем выходные данные из предыдущего блока/слоя (x) через два сверточных слоя, каждый раз

принимая выход из предыдущего слоя в качестве входа в следующий слой. Наконец, последний выход из блока (удерживаемый в переменной x) складывается (матричным сложением) с изначальным значением x (shortcut). Это и есть отождествляющая связь, которую принято называть просто *аббревиатурой*:

```

shortcut = x                                ← Запомнить вход в блок
x = layers.Conv2D(64, kernel_size=(3, 3), strides=(1, 1), padding='same')(x)
x = layers.ReLU()(x)
x = layers.Conv2D(64, kernel_size=(3, 3), strides=(1, 1), padding='same')(x)
x = layers.ReLU()(x)                        ← Выход из сверточной последовательности
x = layers.add([shortcut, x])               ← Матричное сложение выход со входом

```

Теперь давайте соберем всю сеть вместе, используя процедурный стиль. В дополнение к этому нам нужно добавить входной сверточный слой сети ResNet, а затем классификатор в форме глубокой нейросети.

Как и в примере с VGG, мы определяем процедуру (функцию) для генерирования шаблона остаточного блока, следуя шаблону, который мы использовали в предыдущем фрагменте исходного кода. Для нашей процедуры `residual_block()` мы передаем число фильтров для блока и входной слой (выход из предыдущего слоя).

Архитектуры ResNet на входе принимают вектор (224, 224, 3) – изображение RGB (3 канала) размером 224 (высота) × 224 (ширина) пикселей. Первый слой – это базовый сверточный слой, состоящий из свертки с использованием довольно крупного фильтра размером 7×7. Выход (карты признаков) затем сокращается в размере слоем максимального сведения.

После начального сверточного слоя идет последовательность групп остаточных блоков. Каждая последующая группа удваивает число фильтров (аналогично архитектуре VGG). Однако, в отличие от VGG, между группами нет слоя сведения, который сокращал бы размер карт признаков. Теперь если соединить эти блоки друг с другом напрямую, то у нас возникнет проблема. Вход в следующий блок имеет форму, основанную на размере фильтра предыдущего блока (назовем его X). Следующий блок, удвоив фильтры, приведет к тому, что выход из этого остаточного блока удвоится (назовем его $2X$). Отождествляющая связь попытается сложить входную матрицу (X) и выходную матрицу ($2X$). Хлоп – и мы получаем ошибку, сообщающую о том, что невозможно оттранслировать (для операции сложения) матрицы разных размеров.

В случае ResNet это решается путем добавления сверточного блока между каждой «удваивающей» группой остаточных блоков. Как показано на рис. 3.12, сверточный блок удваивает фильтры, чтобы реформировать размер, и удваивает шаг, чтобы сократить размер карт признаков на 75 % (выполняет сведение признаков).

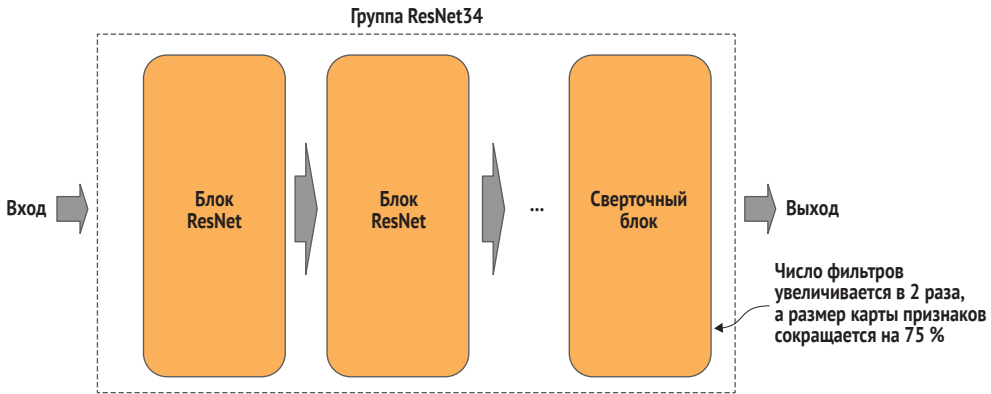


Рис. 3.12 Сверточный блок выполняет сведение и удваивает число карт признаков для следующей сверточной группы

Выход из последней группы остаточных блоков передается в слой сведения и разглаживания (GlobalAveragePooling2D), который затем передается в один плотный (Dense) слой численностью 1000 узлов (по числу классов):

```
from tensorflow.keras import Model
import tensorflow.keras.layers as layers
```

`def residual_block(n_filters, x):` ← Остаточный блок как процедура

```
""" Создать остаточный блок свертки
    n_filters: число фильтров
    x          : данные, поступающие на вход в блок
    """
    shortcut = x
    x = layers.Conv2D(n_filters, (3, 3), strides=(1, 1), padding="same",
                      activation="relu")(x)
    x = layers.Conv2D(n_filters, (3, 3), strides=(1, 1), padding="same",
                      activation="relu")(x)
    x = layers.add([shortcut, x])
    return x
```

`def conv_block(n_filters, x):` ← Сверточный блок как процедура

```
""" Создать блок свертки без сведения
    n_filters: число фильтров
    x          : данные, поступающие на вход в блок
    """
    x = layers.Conv2D(n_filters, (3, 3), strides=(2, 2), padding="same",
                      activation="relu")(x)
    x = layers.Conv2D(n_filters, (3, 3), strides=(2, 2), padding="same",
                      activation="relu")(x)
    return x
```

Входной тензор → `inputs = layers.Input(shape=(224, 224, 3))`
`x = layers.Conv2D(64, kernel_size=(7, 7), strides=(2, 2), padding='same',`

```

activation='relu')(inputs)
x = layers.MaxPool2D(pool_size=(3, 3), strides=(2, 2), padding='same')(x)

for _ in range(2):
    x = residual_block(64, x)

x = conv_block(128, x)
for _ in range(3):
    x = residual_block(128, x)

x = conv_block(256, x)
for _ in range(5):
    x = residual_block(256, x)

x = conv_block(512, x)
x = residual_block(512, x)

x = layers.GlobalAveragePooling2D()(x)

outputs = layers.Dense(1000, activation='softmax')(x)

model = Model(inputs, outputs)

```

Первый сверточный слой, где сведенные карты признаков будут сокращены на 75 %

Первая группа остаточных блоков численностью 64 фильтра

Удваивает размер фильтров и сокращает карты признаков на 75 % (шаг $s = 2, 2$), чтобы вписаться в следующую остаточную группу

Теперь давайте выполним метод `model.summary()`. Мы увидим, что суммарное число усваиваемых параметров составляет 21 млн. Это отличается от архитектуры VGG16, которая имеет 138 млн параметров. Таким образом, архитектура ResNet в шесть раз быстрее в вычислительном отношении. Это сокращение в основном достигается за счет строительства остаточных блоков. Обратите внимание, что внутренняя часть в форме глубокой нейросети – это лишь один выходной плотный слой. По сути, внутренней части нет. Ранние группы остаточных блоков действуют как внешняя часть в форме сверточной нейросети, выполняющая обнаружение признаков, тогда как последние остаточные блоки выполняют классифицирование. При этом, в отличие от VGG, не было необходимости иметь несколько полносвязных плотных слоев, что существенно увеличило бы число параметров.

В отличие от предыдущего примера сведения, в котором размер каждой карты признаков сокращается в соответствии с размером шага, библиотечный объект сведения на основе глобального усреднения `GlobalAveragePooling2D` похож на версию сведения с турбо-наддувом: каждая карта признаков заменяется одним-единственным значением, которое в данном случае является средним из всех значений на соответствующей карте признаков. Например, если на входе у нас 256 карт признаков, то на выходе будет 1-мерный вектор размером 256. После архитектуры ResNet на практике на послед-

ней стадии сведения в глубоких сверточных нейронных сетях стало принято использовать сведение на основе глобального усреднения, `GlobalAveragePooling2D`, что позволило существенно сократить число параметров, поступающих в классификатор, без существенной потери представительной мощности.

Еще одним преимуществом является отождествляющая связь, которая обеспечивает возможность добавления более глубоких слоев без деградации для более высокой точности.

Архитектура ResNet50 представила вариант остаточного блока, именуемый *бутылочным остаточным блоком*¹. В этой версии группа из двух сверточных слоев 3×3 заменяется группой из 1×1 , затем 3×3 , а потом 1×1 сверточных слоев. Первая свертка 1×1 выполняет редукцию размерности, сокращая вычислительную сложность, а последняя свертка восстанавливает размерность, увеличивая число фильтров в 4 раза. Средняя свертка 3×3 называется *сверткой в форме бутылочного горлышка*, т. е. узкой, как горлышко бутылки. Изображенный на рис. 3.13 бутылочный остаточный блок позволяет создавать более глубокие нейронные сети без деградации и дальнейшего снижения вычислительной сложности.

Ниже приведен фрагмент исходного кода для написания бутылочного остаточного блока в качестве реиспользуемой функции:

```
def bottleneck_block(n_filters, x):
    """ Создать остаточный блок сверток, имеющий форму бутылочного горлышка
        n_filters: число фильтров
        x          : данные, поступающие на вход в блок
    """
    shortcut = x
    x = layers.Conv2D(n_filters, (1, 1), strides=(1, 1), padding="same",
                      activation="relu")(x)
    x = layers.Conv2D(n_filters, (3, 3), strides=(1, 1), padding="same",
                      activation="relu")(x)
    x = layers.Conv2D(n_filters * 4, (1, 1), strides=(1, 1), padding="same",
                      activation="relu")(x)
    x = layers.add([shortcut, x])
    return x
```

Свертка 3×3 для выделения признаков

Свертка 1×1 в форме бутылочного горлышка для редукции размерности

Проекционная свертка 1×1 для расширения размерности

Матричное сложение входа с выходом

Остаточные блоки ввели понятия представительной мощности и эквивалентности представления. *Представительная мощность* – это показатель мощности блока как средства выделения признаков. *Эквивалентность представления* – это идея о том, что блок может участвовать в более низкой вычислительной сложности при сохранении представительной мощности. Было продемонстрировано, что конструкция остаточного бутылочного блока позволяет поддерживать представительную мощность блока ResNet34 при более низкой вычислительной сложности.

¹ То есть в форме бутылочного горлышка. – Прим. перев.



Рис. 3.13 Для редукции и расширения размерности в конструкции в форме бутылочного горлышка используются свертки 1×1

3.4.2 Пакетная нормализация

Еще одна проблема с добавлением более глубоких слоев в нейронную сеть касается *исчезающего градиента*. На самом деле речь идет о компьютерном оборудовании. Во время тренировки (процесса обратного распространения и градиентного спуска) в каждом слое веса умножаются на очень малые числа, в частности на числа меньше 1. Как вы знаете, два числа меньше 1, умноженных вместе, дают еще меньшее число. Когда эти крошечные значения распространяются по более глубоким слоям, они непрерывно сокращаются. В какой-то момент компьютерное оборудование больше не способно представлять значение – отсюда и исчезающий градиент.

Указанная проблема усугубляется еще более, если для матричных операций пытаться использовать вещественные числа с половинной точностью (16-битовые вещественные числа) по сравнению с вещественными числами с одинарной точностью (32-битовыми вещественными числами). Преимущество первых заключается в том, что веса (и данные) хранятся в половине объема пространства – и, задействуя общее эмпирическое правило, сокращая вычислительный размер вдвое, можно за вычислительный цикл исполнять в четыре раза больше инструкций. Проблема, конечно же, в том, что с еще меньшей точностью мы столкнемся с исчезающим градиентом даже раньше.

Пакетная нормализация – это технический прием, который применяется к выходу из слоя (до или после активационной функции). Не вдаваясь в статистический аспект, он нормализует сдвиг в весах

по мере того, как они тренируются. Это имеет несколько преимуществ: он сглаживает (по всему пакету) объем изменений, тем самым замедляя возможность получения числа настолько малого, что его невозможно будет представить оборудованием. Вдобавок за счет уменьшения величины сдвига между весами сходжение может происходить быстрее, используя более высокую скорость усвоения и сокращая совокупное время тренировки. В TF.Keras пакетная нормализация добавляется в слой библиотечным классом `BatchNormalization`.

В более ранних имплементациях пакетная нормализация имплементировалась постактивационно. Пакетная нормализация происходила после свертки и плотных слоев. В то время обсуждался вопрос о том, должна ли пакетная нормализация выполняться до активационной функции либо после нее. В данном примере исходного кода используется постактивационная пакетная нормализация как до, так и после активационной функции, как в свертке, так и в плотном слое:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Conv2D, ReLU, BatchNormalization, Flatten
from tensorflow.keras.layers import Dense

model = Sequential()

model.add(Conv2D(64, (3, 3), strides=(1, 1), padding='same',
                input_shape=(128, 128, 3)))
model.add(BatchNormalization())
model.add(ReLU())
model.add(Flatten())
model.add(Dense(4096))

model.add(ReLU())
model.add(BatchNormalization())
```

Добавляет пакетную нормализацию до активации

Добавляет пакетную нормализацию после активации

3.4.3 Архитектура ResNet50

Архитектура ResNet50 – это хорошо известная модель, которая неплохо реиспользуется в качестве стоковой модели, например для переноса обучения, в качестве совместных слоев в обнаружении объектов и для сравнительного анализа результативности. Модель имеет три версии: v1, v1.5 и v2.

ResNet50 v1 формализовала концепцию сверточной группы. Это набор сверточных блоков, которые имеют общую конфигурацию, такую как число фильтров. В версии v1 нейронная сеть раскладывается на группы, и каждая группа удваивает число фильтров из предыдущей группы.

Вдобавок концепция отдельного сверточного блока с целью удвоения числа фильтров была удалена и заменена остаточным блоком, в котором используется *линейная проекция*. Каждая группа начинается с остаточного блока, в котором используется линейная проекция

на отождествляющую связь, чтобы удваивать число фильтров, тогда как остальные остаточные блоки передают входные данные непосредственно на выход для операции матричного сложения. Кроме того, в первой свертке 1×1 в остаточном блоке с линейной проекцией используется шаг 2 (сведение признаков), также именуемый *пошаговой сверткой*, сокращая размеры карт признаков на 75 %, как показано на рис. 3.14.

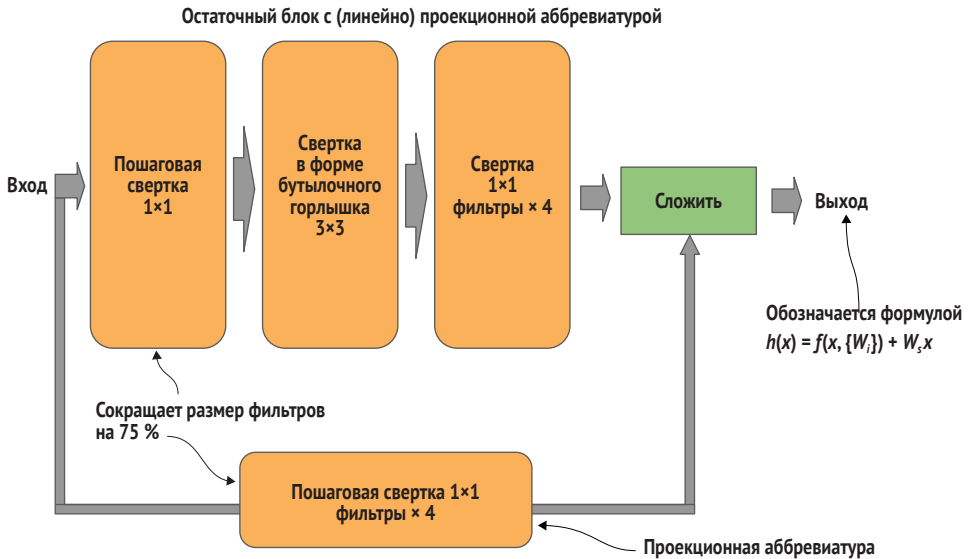


Рис. 3.14 Отождествляющая связь заменена проекцией 1×1 , чтобы на сверточном выходе соответствовать числу карт признаков для операции матричного сложения

Ниже приведена имплементация архитектуры ResNet50 v1 с использованием блока в форме бутылочного горлышка в сочетании с пакетной нормализацией:

```
from tensorflow.keras import Model
import tensorflow.keras.layers as layers

def identity_block(x, n_filters):
    """ Создать остаточный блок свертки, имеющий форму бутылочного горлышка
    n_filters: число фильтров
    x          : данные, поступающие на вход в блок
    """
    shortcut = x

    x = layers.Conv2D(n_filters, (1, 1), strides=(1, 1))(x)
    x = layers.BatchNormalization()(x)
    x = layers.ReLU()(x)

    x = layers.Conv2D(n_filters, (3, 3), strides=(1, 1), padding="same")(x)
    x = layers.BatchNormalization()(x)
```

```

x = layers.ReLU()(x)

x = layers.Conv2D(n_filters * 4, (1, 1), strides=(1, 1))(x)
x = layers.BatchNormalization()(x)

x = layers.add([shortcut, x])
x = layers.ReLU()(x)

return x

```

Проекционный блок как процедура

```

def projection_block(x, n_filters, strides=(2,2)):
    """ Создать блок сверток со сведением признаков
        Увеличить число фильтров в 4 раза
        X      : данные, поступающие на вход в блок
        n_filters: число фильтров
    """

    shortcut = layers.Conv2D(4 * n_filters, (1, 1), strides=strides)(x)
    shortcut = layers.BatchNormalization()(shortcut)

    x = layers.Conv2D(n_filters, (1, 1), strides=strides)(x)
    x = layers.BatchNormalization()(x)
    x = layers.ReLU()(x)

    x = layers.Conv2D(n_filters, (3, 3), strides=(1, 1), padding='same')(x)
    x = layers.BatchNormalization()(x)
    x = layers.ReLU()(x)

    x = layers.Conv2D(4 * n_filters, (1, 1), strides=(1, 1))(x)
    x = layers.BatchNormalization()(x)

    x = layers.add([x, shortcut])
    x = layers.ReLU()(x)

    return x

```

Проекционная свертка 1×1 на аббревиатуре для соответствия размеру на выходе

```

inputs = layers.Input(shape=(224, 224, 3))

x = layers.ZeroPadding2D(padding=(3, 3))(inputs)
x = layers.Conv2D(64, kernel_size=(7, 7), strides=(2, 2), padding='valid')(x)
x = layers.BatchNormalization()(x)
x = layers.ReLU()(x)
x = layers.ZeroPadding2D(padding=(1, 1))(x)
x = layers.MaxPool2D(pool_size=(3, 3), strides=(2, 2))(x)

x = projection_block(64, x, strides=(1,1))
for _ in range(2):
    x = identity_block(64, x)

x = projection_block(128, x)

for _ in range(3):
    x = identity_block(128, x)

x = projection_block(256, x)

```

Каждая сверточная группа после первой группы начинается с проекционного блока

```

for _ in range(5):
    x = identity_block(256, x)

x = projection_block(512, x)

for _ in range(2):
    x = identity_block(512, x)

x = layers.GlobalAveragePooling2D()(x)

outputs = layers.Dense(1000, activation='softmax')(x)

model = Model(inputs, outputs)

```

Как изображено на рис. 3.15, версия v1.15 внедрила разложение бутылочной конструкции и дальнейшее снижение вычислительной сложности при сохранении представительной мощности. Сведение признаков (шаги = 2) в остаточном блоке с линейной проекцией перемещено из первой свертки 1×1 в свертку 3×3 , тем самым снизив вычислительную сложность и увеличив результаты на ImageNet на 0.5 %.

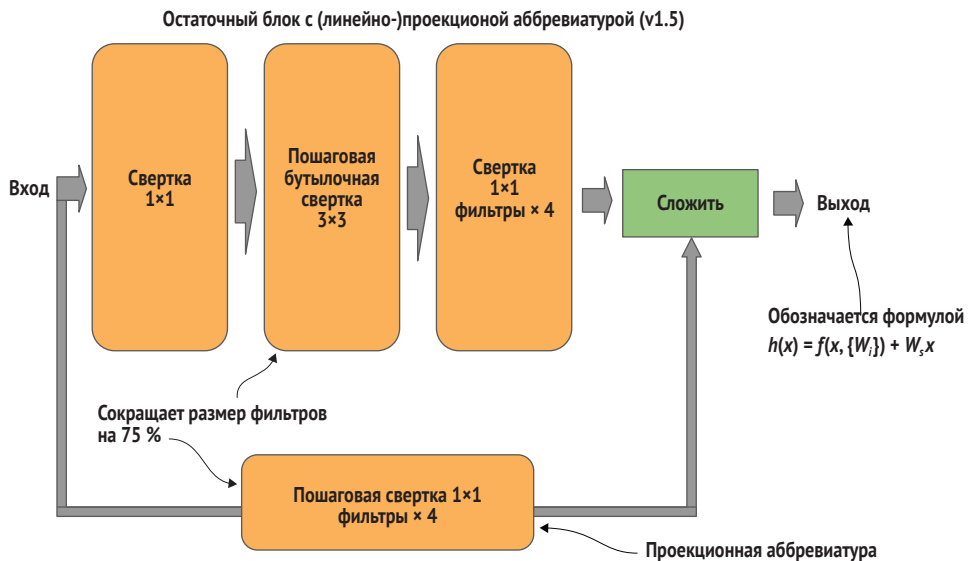


Рис. 3.15 Редукция размерности переместилась из свертки 1×1 в свертку 3×3

Ниже приведена имплементация остаточного блока ResNet50 v1 с проекционной связью:

```

def projection_block(x, n_filters, strides=(2,2)):
    """ Создать блок свертки со сведением признаков
        Увеличить число фильтров в 4 раза
        X      : данные, поступающие на вход в блок
        n_filters: число фильтров
    """

```

```

"""
shortcut = layers.Conv2D(4 * n_filters, (1, 1), strides=strides)(x)
shortcut = layers.BatchNormalization()(shortcut)

x = layers.Conv2D(n_filters, (1, 1), strides=(1, 1))(x)
x = layers.BatchNormalization()(x)
x = layers.ReLU()(x)

x = layers.Conv2D(n_filters, (3, 3), strides=(2, 2), padding='same')(x) ←
x = layers.BatchNormalization()(x)
x = layers.ReLU()(x)
# Бутилочное горлышко перемещено
# в свертку 3×3 с шагом 2

x = layers.Conv2D(4 * n_filters, (1, 1), strides=(1, 1))(x)
x = layers.BatchNormalization()(x)

x = layers.add([x, shortcut])
x = layers.ReLU()(x)
return x

```

ResNet50 v2 ввела *предактивационную пакетную нормализацию* (BN-RE-Conv), в которой пакетная нормализация и активационные функции размещаются до (а не после) соответствующей свертки или плотного слоя. Теперь это стало общепринятой практикой, как показано ниже в случае имплементации остаточного блока с отождествляющей связью в версии v2:

```

def identity_block(x, n_filters):
    """ Создать бутилочный остаточный блок свертки
        n_filters: число фильтров
        x          : данные, поступающие на вход в блок
    """
    shortcut = x

    x = layers.BatchNormalization()(x)
    x = layers.ReLU()(x)
    x = layers.Conv2D(n_filters, (1, 1), strides=(1, 1))(x)

    x = layers.BatchNormalization()(x)
    x = layers.ReLU()(x)
    x = layers.Conv2D(n_filters, (3, 3), strides=(1, 1), padding="same")(x)

    x = layers.BatchNormalization()(x)
    x = layers.ReLU()(x)
    x = layers.Conv2D(n_filters * 4, (1, 1), strides=(1, 1))(x)

    x = layers.add([shortcut, x])
    return x

```

Пакетная
нормализация
перед
сверткой

Резюме

- Сверточная нейронная сеть может быть описана как добавление внешней части к глубокой нейронной сети.

- Предназначение внешней части в форме сверточной нейросети заключается в редукции высокоразмерного пиксельного ввода к низкоразмерному отображению/представлению признаков.
- Меньшая размерность отображения/представления признаков делает практичным проведение глубокого обучения с изображениями реального мира.
- Изменение размера изображений и сведение используются для сокращения числа параметров в модели без потери информации.
- Использование каскадирующего набора фильтров для обнаружения признаков имеет сходство с человеческим глазом.
- Архитектура VGG формализовала концепцию повторяющегося сверточного шаблона.
- Остаточные сети ввели концепцию реиспользования признаков и продемонстрировали способность получать более высокую точность при том же числе слоев, что и в VGG, и углубляться в слои, достигая более высокой точности.
- Пакетная нормализация позволила моделям углубляться в слои, достигая более высокой точности, прежде чем подвергаться воздействию исчезающих или взрывающихся градиентов.

4

Основы процесса тренировки

Эта глава охватывает следующие ниже темы:

- прямая подача и обратное распространение;
- разбивка и предобработка наборов данных;
- использование валидационных данных для слежения за переподгонкой;
- использование контрольных точек и ранней остановки для проведения более экономичной тренировки;
- использование гиперпараметров вместо модельных параметров;
- тренировка под инвариантность к местоположению и масштабу;
- сборка дисковых наборов данных и доступ к ним;
- сохранение и последующее восстановление натренированной модели.

Эта глава охватывает основы процесса тренировки модели. До 2019 года большинство моделей проходили тренировку в соответствии с этим набором основополагающих шагов. Рассматривайте эту главу в качестве фундамента.

В данной главе мы рассмотрим методы, технические приемы и лучшие практические подходы, разработанные с течением времени путем экспериментирования и посредством проб и ошибок. Мы начнем с проведения ревизии методики прямой подачи данных через сеть и обратного распространения потерь. Хотя эти концепции

и методы уже существовали до глубокого обучения, многочисленные улучшения, внедренные за последние годы, сделали модельную тренировку практичной, в частности в том, как мы разбиваем данные, подаем их в модель, а затем обновляем веса, используя градиентный спуск во время обратного распространения. Эти улучшения в технических приемах обеспечили средства для тренировки моделей до схождения, то есть до точки, в которой точность предсказательной модели выходит на плато.

Кроме того, были разработаны некоторые другие тренировочные приемы по предобработке и обогащению данных, которые позволили поднять схождение до более высоких плато и помогли моделям делать более качественные обобщения на данные, на которых она не тренировалась. Дальнейшие улучшения продолжали делать процесс тренировки экономичнее посредством гиперпараметрического поиска и настройки, а также использования контрольных точек и ранней остановки, более эффективных форматов и методов извлечения данных из дискового хранилища во время тренировки. Все эти технические приемы в совокупности привели к тому, что глубокое обучение стало практичным для реально существующих приложений как с вычислительной, так и с экономической точки зрения.

4.1 Прямая подача и обратное распространение

Давайте начнем с обзора контролируемой тренировки. Во время тренировки модели вы подаете данные через модель и вычисляете уровень правильности предсказанных результатов – *потерю*. Затем потеря распространяется в обратном направлении, чтобы внести обновления в модельные параметры, то есть то, что модель и усваивает, – значения параметров.

При проведении тренировки модели вы начинаете с тренировочных данных, весомо представляющих целевую среду, в которой будет развернута модель. Другими словами, эти данные являются выборочным распределением популяционного распределения. Тренировочные данные состоят из примеров. Каждый пример имеет две части: признаки, т. н. *независимые переменные*, и соответствующие метки, т. н. *зависимую переменную*.

Метки также именуются *основополагающими истинами*¹ («правильными ответами»). Наша цель состоит в том, чтобы натрени-

¹ Фундаментальная истина (ground truth), или непреложная, эмпирическая истина, – это информация, о которой известно, что она является реальной, или истинной, полученной путем прямого наблюдения и измерения (т. е. эмпирически), в отличие от информации, полученной путем логического или иного вывода. – *Прим. перев.*

ровать модель, которая после ее развертывания и предоставления ей примеров без меток из популяции (примеров, которые модель никогда не встречала раньше) – в результате контролируемого усвоения – наделяется способностью обобщать, чтобы точно предсказывать метку («правильный ответ»). Этот шаг называется *предсказательным выводом*.

Во время тренировки мы подаем данные в модель *пакетами* (т. н. партиями, или *выборками*) из тренировочных данных через входной слой (через т. н. *дно* модели). Затем тренировочные данные преобразовываются параметрами (весами и смещениями) в слоях модели по мере их продвижения к выходным узлам (к т. н. *вершине* модели). В выходных узлах мы измеряем нашу удаленность от «правильных» ответов, которая, опять же, называется *потерей*. Затем мы распространяем потери в обратном направлении по слоям модели и обновляем параметры, делая их ближе к получению правильного ответа в следующем пакете.

Мы продолжаем повторять этот процесс до тех пор, пока не достигнем *схождения*, точки, которую можно было бы описать следующими словами: «это максимально точное состояние, которого можно добиться на данном прогоне тренировки».

4.1.1 Подача данных

Подача данных – это процесс отбора пакетов из тренировочных данных и пропуска пакетов через модель в прямом направлении, а затем вычисления потери на выходе. Пакет может состоять из одного или нескольких выбранных наугад примеров из тренировочных данных.

Величина пакета обычно постоянна и называется *размером* (мини-) *пакета*. Все тренировочные данные разбиты на пакеты, и обычно каждый пример появляется только в одном пакете.

Все тренировочные данные подаются в модель несколько раз. Всякий раз, когда мы подаем все тренировочные данные целиком, это называется *эпохой*. Каждая эпоха представляет собой отличающуюся случайную перестановку примеров в пакетах – то есть, как показано на рис. 4.1, не существует двух эпох с одинаковым порядком следования примеров.

4.1.2 Обратное распространение

В этом разделе мы разведем методику обратного распространения, важность его открытия и принцип использования сегодня.

Предпосылки

Давайте отступим на один шаг назад и углубимся в историю, чтобы понять важность того, как обратное распространение поспособство-

вало успеху глубокого обучения. В ранних нейронных сетях, таких как персептрон и однослойные нейроны, академические исследователи экспериментировали со способами обновления весов, чтобы получить правильный ответ.

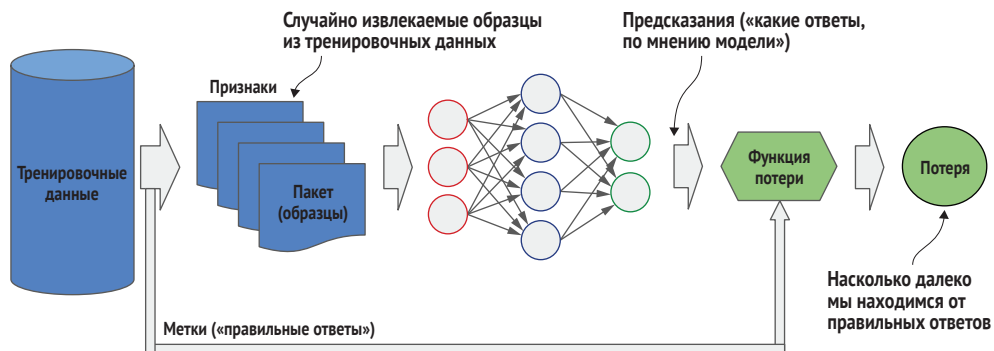


Рис. 4.1 Во время тренировки мини-пакеты из тренировочных данных пропускаются через нейронную сеть в прямом направлении

Когда они работали всего с несколькими нейронами и простыми задачами, логичными первыми попытками были просто случайные обновления. В конце концов, кто бы мог подумать, работала случайная догадка. Однако, как ни крути, такой подход не масштабировался на крупные числа нейронов (скажем, тысячи) и реально существующие приложения; на то, чтобы сделать правильную случайную догадку, могли уйти миллионы лет.

Следующим логическим шагом было попытаться сделать случайное значение пропорциональным удаленности предсказания. Другими словами, чем дальше, тем больше диапазон случайных значений; и чем ближе, тем меньше диапазон. Неплохо – теперь у нас меньше времени, может быть, тысяча лет, чтобы угадать правильные случайные значения в реально существующем приложении.

В итоге академические исследователи поэкспериментировали с многослойными персептронами, и технический прием, позволяющий делать случайные значения пропорциональными их удаленности от правильного ответа, – потеря – просто не сработал. Они обнаружили, что при наличии нескольких слоев эта методика приводит к тому, что левая рука – один слой – отменяет работу правой руки – другого слоя.

Эти исследователи обнаружили, что хотя обновления весов выходного слоя относятся к потере в предсказании, обновления весов в более ранних слоях относятся к обновлениям в следующем слое. Таким образом, была сформулирована концепция обратного распространения. На этом этапе в своих расчетах обновлений академические исследователи вышли за рамки использования случайных распределений. Были опробованы многочисленные подходы, но улучшений

не наблюдалось до тех пор, пока не была разработана методика обновления весов не до величины изменений в следующем слое, а относительно темпа изменений – отсюда открытие и развитие методов градиентного спуска.

ОБРАТНОЕ РАСПРОСТРАНЕНИЕ НА ОСНОВЕ ПАКЕТОВ

После того как каждый пакет тренировочных данных пропущен через модель в прямом направлении и вычислена потеря, потеря распространяется через модель в обратном направлении. Мы идем слой за слоем, обновляя параметры модели (веса и смещения), начиная с верхнего слоя (выхода) и продвигаясь к нижнему слою (входу). Обновление параметров представляет собой комбинацию потери, значений текущих параметров и обновлений, внесенных в текущий слой.

Общий метод его выполнения основан на *градиентном спуске*. Оптимизатор – это имплементация градиентного спуска, задача которого состоит в обновлении параметров для минимизации потери (максимального приближения к правильному ответу) в последующих пакетах. Рисунок 4.2 иллюстрирует описанный процесс.




Рис. 4.2 Вычисленная потеря из мини-пакета распространяется в обратном направлении; оптимизатор обновляет веса, чтобы минимизировать потерю в следующем пакете

4.2 Разбивка набора данных

Набор данных представляет собой коллекцию примеров, которые достаточно велики и разнообразны, чтобы весомерно представлять моделируемую популяцию (выборочное распределение). Когда набор данных соответствует этому определению и очищен (не зашумлен), находится в формате, готовом для машинно усвояемой тренировки, мы называем его *курируемым набором данных*. В этой книге детали

очистки набора данных не рассматриваются, так как это крупная и разнообразная тема, которая сама по себе составила бы книгу. Однако там, где это уместно, мы все же затрагиваем аспекты очистки данных на протяжении всей книги.

Для академических и исследовательских целей доступно большое разнообразие курируемых наборов данных. Для классифицирования изображений есть несколько хорошо известных, таких как MNIST (представлен в главе 2), CIFAR-10/100, SVHN, Flowers, and Cats vs. Dogs (Цветы и кошки против собак). MNIST и CIFAR-10/100 (аббр. от англ. Canadian Institute for Advanced Research – Канадский институт перспективных исследований) встроены в каркас TF.Keras. SVHN (аббр. от англ. Street View Home Numbers – Номера домов с видом на улицу), Flowers, and Cats vs. Dogs доступны вместе с наборами данных TensorFlow (TFDS). Мы будем использовать эти наборы данных в учебных целях на протяжении всего этого раздела.

Имея в своем распоряжении курируемый набор данных, следующим шагом будет его разбивка на примеры, которые будут использоваться для тренировки, и те, которые будут использоваться для тестирования (т. н. *оценочные*, или *отложенные*). Мы тренируем модель той порцией набора данных, которые являются тренировочными. Если допустить, что тренировочные данные являются хорошим выборочным распределением (весомо представляют распределение популяции), то точность тренировочных данных должна отражать точность, получаемую при развертывании в реально существующей среде для предсказания на примерах из популяции, не встречавшихся моделью во время тренировки.

Но как проверить истинность этого утверждения до того, как модель будет развернута? Отсюда и вытекает предназначение тестовых (отложенных) данных. Мы откладываем порцию набора данных, с помощью которой будем тестировать модель, после того как она будет натренирована, чтобы потом убедиться, что мы получили или не получили сопоставимую точность.

Например, предположим, что мы закончили тренировку и у нас 99%-ная точность на тренировочных данных, но только 70%-ная точность на тестовых данных. Что-то пошло не так (например, переподгонка). Так сколько же тогда данных следует откладывать на тренировку и тестирование? Исторически сложилось эмпирическое соотношение 80/20: 80 % для тренировки и 20 % для тестирования. Сейчас эта пропорция изменилась, но мы начнем с указанного эмпирического правила и в последующих главах обсудим современные обновления.

4.2.1 Тренировочный и тестовый наборы

Важно то, что мы можем допустить, что наш набор данных достаточно велик, что если мы разделим его на 80 % и 20 %, и примеры будут выбираться случайно таким образом, чтобы оба набора данных были

хорошими выборочными распределениями, весомо представляющими популяционное распределение, то после развертывания модели она будет делать предсказания (выполнять предсказательный вывод). Рисунок 4.3 иллюстрирует этот процесс.

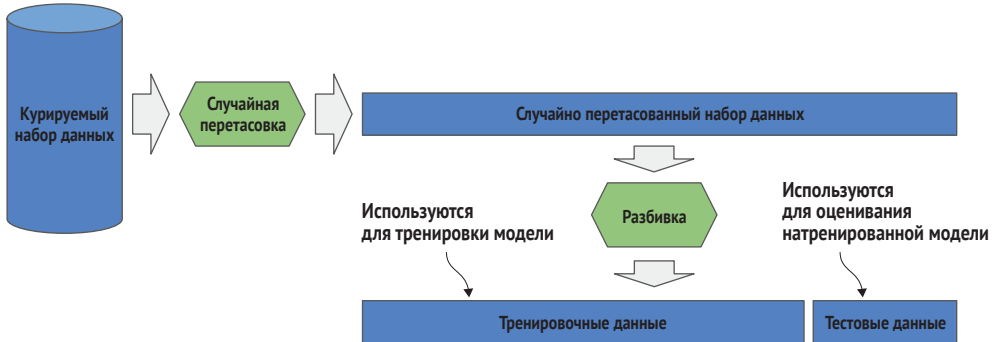


Рис. 4.3 Тренировочные данные сначала случайно перетасовываются, а затем разбиваются на тренировочные и тестовые данные

Давайте начнем с пошагового процесса тренировки с помощью курируемого набора данных. На первом шаге мы импортируем встроенный в TF.Keras курируемый набор данных MNIST, как показано в следующем ниже исходном коде. Встроенные в TF.Keras наборы данных имеют метод `load_data()`. Этот метод загружает в память набор данных, уже случайно перетасованный и предварительно разбитый на тренировочные и тестовые данные. И тренировочные, и тестовые данные делятся дальше на признаки (в нашем случае данные изображений) и соответствующие метки (числовые значения от 0 до 9, представляющие каждую цифру). Во время тренировки и тестирования по традиции на признаки и метки принято ссылаться соответственно как на (x_train, y_train) и (x_test, y_test) :

```

from tensorflow.keras.datasets import mnist ← MNIST – это встроенный
                                              в каркас набор данных

(x_train, y_train), (x_test, y_test) = mnist.load_data() ←
print(x_train.shape, y_train.shape)                     Встроенный набор данных автоматически
print(x_test.shape, y_test.shape)yp                     перетасовывается в случайном порядке
                                                         и предварительно разбивается на
                                                         тренировочные и тестовые данные
  
```

Набор данных MNIST состоит из 60 000 тренировочных и 10 000 тестовых примеров с ровным (сбалансированным) распределением по десяти цифрам от 0 до 9. Каждый пример состоит из полутонового изображения размером 28×28 пикселей (одноканального). Как показывают приведенный ниже результат, тренировочные данные (x_train, y_train) состоят из 60 000 примеров изображений размером 28×28 и соответствующих 60 000 меток, тогда как тестовые данные (x_test, y_test) состоят из 10 000 примеров и меток:

```
(60000, 28, 28) (60000,)
(10000, 28, 28) (10000,)
```

4.2.2 Кодирование с одним активным состоянием

Давайте построим простую глубокую нейросеть, чтобы натренировать ее на нашем курируемом наборе данных. В следующем ниже примере исходного кода мы начинаем с разглаживания входного изображения 28×28 в 1-мерный вектор с помощью слоя Flatten, за которым затем следуют два скрытых плотных (Dense) слоя по 512 узлов каждый, в каждом из которых по традиции используется активационная функция `relu`. Наконец, выходным слоем является плотный слой с 10 узлами, по одному на каждую цифру. Поскольку мы имеем дело с мультиклассовым классификатором, то активационной функцией для выходного слоя является `softmax`.

Далее мы компилируем модель в форме мультиклассового классификатора, для которого по традиции в качестве потери используется функция `categorical_crossentropy`, а в качестве оптимизатора – `adam`:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Flatten, Dense

model = Sequential()
model.add(Flatten(input_shape=(28, 28)))
model.add(Dense(512, activation='relu'))
model.add(Dense(512, activation='relu'))
model.add(Dense(10, activation='softmax'))
model.compile(loss='categorical_crossentropy',
              optimizer='adam',
              metrics=['acc'])
```

Разглаживает 2-мерное
полутоновое изображение
в 1-мерный вектор
для глубокой нейросети

←

Фактический входной слой
глубокой нейросети после
разглаживания изображения

←

Скрытый слой

←

Выходной слой глубокой нейросети

Натренировать эту модель с помощью указанного набора данных можно элементарно, применив метод `fit()`. В качестве параметров мы передаем тренировочные данные (`x_train`, `y_train`). Остальные именованные параметры оставляем со значениями, заданными по умолчанию:

```
model.fit(x_train, y_train)
```

При выполнении приведенной выше строки исходного кода вы увидите сообщение об ошибке¹:

```
ValueError: You are passing a target array of shape (60000, 1) while using
as loss 'categorical_crossentropy'. 'categorical_crossentropy' expects
targets to be binary matrices (1s and 0s) of shape (samples, classes).
```

¹ *Перевод сообщения:* Ошибка значения: вы передаете целевой массив формы (60000, 1), используя в качестве потери функцию 'categorical_crossentropy'. Указанная функция потери ожидает, что целями будут двоичные матрицы (единицы и нули), имеющие форму (samples, classes). – Прим. перев.

Что пошло не так? Проблема с выбранной нами функцией потерь. Она будет сравнивать разницу между каждым выходным узлом и соответствующим ожидаемым выходом. Например, если ответом является цифра 3, то нам нужен 10-элементный вектор (по одному элементу на цифру) с единицей (100%-ная вероятность) в индексе 3 и нулями (0%-ная вероятность) в оставшихся индексах. В этом случае нам нужно конвертировать скалярнозначные метки в 10-элементные векторы, в которых 1 установлена в соответствующем индексе. Указанная процедура называется *кодированием с одним активным состоянием*, и она изображена на рис. 4.4¹.

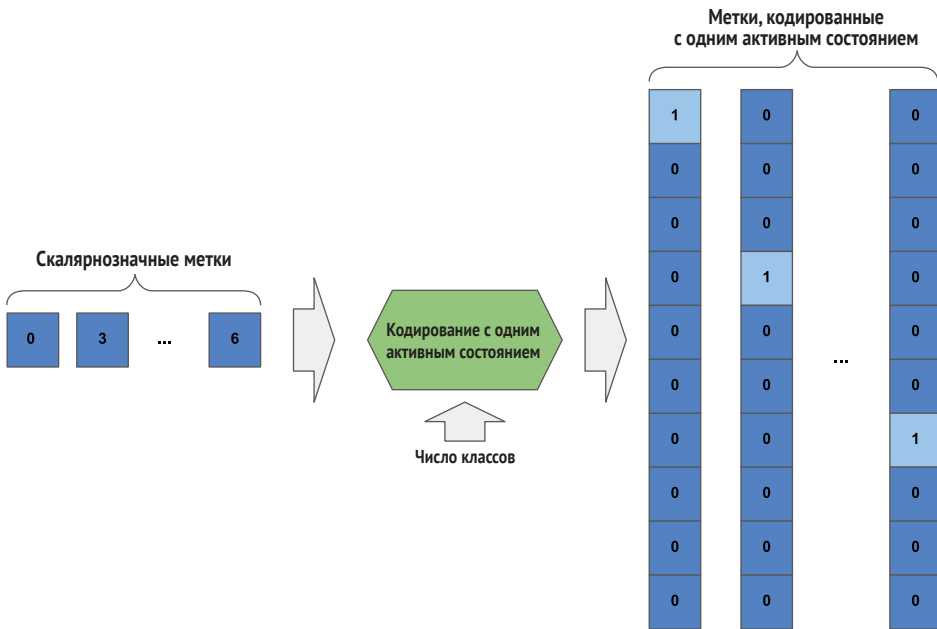


Рис. 4.4 Размер метки, кодированной с одним активным состоянием, совпадает с числом выходных классов

Давайте исправим наш пример, сначала импортировав функцию `to_categorical()` из `TF.Keras`, а затем применив ее для конвертирования скалярнозначных меток в метки в кодировке с одним активным состоянием. Обратите внимание, что в функцию `to_categorical()` мы передаем значение 10. Это делается, чтобы указать размер меток, кодируемых с одним активным состоянием (число классов):

¹ Термин «кодирование с одним активным состоянием» (one-hot encoding) пришло из терминологии цифровых интегральных микросхем, в которой оно описывает конфигурацию микросхемы, допускающую, чтобы только один бит был положительным (активным). – *Прим. перев.*

```

from tensorflow.keras.utils import to_categorical
y_train = to_categorical(y_train, 10)
y_test = to_categorical(y_test, 10)
model.fit(x_train, y_train)

```

Этот метод используется для кодирования с одним активным состоянием

Кодирует тренировочные и тестовые метки с одним активным состоянием

Теперь, когда вы выполните приведенный выше фрагмент, ваш результат будет выглядеть примерно так:

```

60000/60000 [=====] - 5s 81us/sample - loss:
1.3920 - acc: 0.9078

```

Точность на тренировочных данных чуть выше 90 %

Это работает, и мы получили 90%-ную точность на тренировочных данных, но указанный шаг можно упростить. Кодирование с одним активным состоянием встроено в метод `compile()`. В целях его подключения мы просто поменяем функцию потери с `categorical_crossentropy` (категориальная перекрестная энтропия) на `sparse_categorical_crossentropy` (разряженная категориальная перекрестная энтропия). В этом режиме функция потери будет получать метки в виде скалярных значений и, перед тем как выполнять перекрестно-энтропийные расчеты, будет динамически конвертировать их в метки, закодированные с одним активным состоянием.

Мы делаем это в следующем ниже примере и дополнительно устанавливаем именованный параметр `epoch` равным 10, чтобы подавать в модель все тренировочные данные 10 раз подряд:

```

from tensorflow.keras import Sequential
from tensorflow.keras.layers import Flatten, Dense

model = Sequential()
model.add(Flatten(input_shape=(28, 28)))
model.add(Dense(512, activation='relu'))
model.add(Dense(512, activation='relu'))
model.add(Dense(10, activation='softmax'))
model.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
              metrics=['acc'])

from tensorflow.keras.datasets import mnist
(x_train, y_train), (x_test, y_test) = mnist.load_data()

model.fit(x_train, y_train, epochs=10)

```

Загружает набор данных MNIST в память

Тренирует модель MNIST в течение 10 эпох

После 10-й эпохи вы должны увидеть точность на тренировочных данных, примерно равную 97 %:

```

Epoch 10/10
60000/60000 [=====] - 5s 83us/sample - loss:
0.0924 - acc: 0.9776

```

4.3 Нормализация данных

Мы можем это усовершенствовать еще больше. Загружаемые модулем `mnist()` данные изображений представлены в сыром формате; каждое изображение является 28×28 -матрицей целочисленных значений от 0 до 255. Если бы вы проинспектировали параметры (веса и смещения) внутри натренированной модели, то увидели бы, что они представляют очень малые числа, обычно от -1 до 1 . Как правило, когда данные подаются через слой в прямом направлении и параметры одного слоя умножаются матричным умножением на параметры в следующем слое, результатом является очень малое число.

Проблема с приведенным выше примером заключается в том, что входные значения значительно больше (вплоть до 255), что будет порождать крупные числа первоначально по мере их умножения по всем слоям. Это приведет к тому, что параметрам потребуется больше времени на то, чтобы усвоить свои оптимальные значения – если они вообще их усвоят.

4.3.1 Нормализация

Скорость, с которой параметры усваивают оптимальные значения, можно увеличить и поднять наши шансы на схождение (данная тема обсуждается впоследствии), если сплющить входные значения в меньший диапазон, что делается очень просто путем их пропорционального сжатия в диапазон от 0 до 1 путем деления каждого значения на 255.

В следующем ниже исходном коде мы добавим шаг нормализации входных данных, разделив каждое пиксельное значение на 255. Функция `load_data()` загружает набор данных в память в формате NumPy. *NumPy*, высокопроизводительный модуль обработки массивов, написанный на C с оберткой Python (CPython), очень эффективен для подачи данных во время тренировки модели, когда весь тренировочный набор данных целиком находится в памяти. (В главе 13 рассматриваются методы и форматы, когда тренировочный набор данных слишком велик, чтобы поместиться в памяти.)

Массив *NumPy* – это библиотечный класс, в котором имплементирован полиморфизм на арифметических операторах. В нашем примере мы показываем операцию с одним делением (`x_train / 255.0`). Оператор деления переопределен под массивы NumPy и задействует операцию трансляции. Это означает, что на 255.0 будет разделен каждый элемент в массиве.

NumPy по умолчанию оперирует на числах с плавающей точкой двойной точности (64 бита). Параметры в модели `TF.Keras` по умолчанию имеют тип чисел с плавающей точкой одинарной точности (32 бита). С целью повышения эффективности на последнем шаге

мы конвертируем результат трансляционного деления в 32 бита с помощью метода `astype()` библиотеки Numpy. Если бы мы не выполнили эту конверсию, то первоначальное матричное умножение из слоя «вход ко входу» заняло бы вдвое больше машинных циклов (64×32 вместо 32×32):

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Flatten, Dense
import numpy as np

model = Sequential()
model.add(Flatten(input_shape=(28, 28)))
model.add(Dense(512, activation='relu'))
model.add(Dense(512, activation='relu'))
model.add(Dense(10, activation='softmax'))
model.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
              metrics=['acc'])

from tensorflow.keras.datasets import mnist

(x_train, y_train), (x_test, y_test) = mnist.load_data()
x_train = (x_train / 255.0).astype(np.float32)
x_test = (x_test / 255.0).astype(np.float32)
model.fit(x_train, y_train, epochs=10)
```

Нормализует пиксельные данные
в диапазон между 0 и 1

Ниже приведен результат выполнения показанного выше фрагмента исходного кода. Давайте сравним выходные данные при нормализованных входных данных с выходными данными при предыдущих ненормализованных входных данных. При предыдущих входных данных мы достигли 97%-ной точности после 10-й эпохи. При нормализованных входных данных мы достигаем такой же точности всего лишь после второй эпохи и почти 99.5%-ной точности после десятой. Таким образом, мы учились быстрее и точнее при нормализованных входных данных:

```
...
Epoch 2/10
60000/60000 [=====] - 5s 84us/sample - loss:
0.0808 - acc: 0.9744
...
Epoch 10/10
60000/60000 [=====] - 5s 81us/sample - loss:
0.0187 - acc: 0.9943
```

Теперь давайте оценим нашу модель с помощью метода `evaluate()` на тестовых (отложенных) данных, чтобы увидеть, насколько хорошую результативность модель покажет на данных, которые она никогда не видела во время тренировки. Метод `evaluate()` работает в режиме предсказательного вывода: тестовые данные подаются через модель в прямом направлении, чтобы сделать предсказание, но

обратного распространения нет. Параметры модели не обновляются. В конце функция `evaluate()` выдаст потерю и совокупную точность:

```
model.evaluate(x_test, y_test)
```

В следующей ниже распечатке мы видим, что точность составляет около 98 % по сравнению с тренировочной точностью 99.5 %. Это ожидаемо. Во время тренировки всегда происходит небольшая перепогонка. Между тренировкой и тестированием мы ищем очень малую разницу, и в данном случае она составляет около 1.5 %:

```
10000/10000 [=====] - 0s 23us/sample - loss:
0.0949 - acc: 0.9790
```

4.3.2 Стандартизация

Помимо примененной в предыдущем примере нормализации, входные данные можно сплющивать самыми разными способами. Например, некоторые практики машинного обучения предпочитают сжимать входные значения между -1 и 1 (а не между 0 и 1), в результате чего значения центрируются на 0 . Следующая ниже строка исходного кода является примером имплементации, которая делит каждый элемент на половину максимального значения (в данном примере 127.5), а затем вычитает 1 из результата:

```
x_train = ((x_train / 127.5) - 1).astype(np.float32)
```

Приводит ли втискивание значений между -1 и 1 к более качественным результатам, чем между 0 и 1 ? Ни в исследовательской литературе, ни на своем собственном опыте я не встречал ничего, что указывало бы на разницу.

Этот и предыдущий методы не требуют предварительного анализа входных данных, помимо знания максимального значения. Есть еще один технический прием под названием *стандартизация*, который, как считается, дает более качественный результат. Однако для этого требуется предварительный анализ (скан) всех входных данных, чтобы найти их среднее значение и стандартное отклонение. Затем данные центрируются на среднем значении полного распределения входных данных, и значения распределяются между \pm одно стандартное отклонение. В следующем ниже исходном коде стандартизация имплементирована с использованием методов NumPy `np.mean()` и `np.std()` и применена к входным данным, находящимся в памяти в виде многомерного массива NumPy:

Вычисляет среднее значение для пиксельных данных

```
import numpy as np
mean = np.mean(x_train)
std = np.std(x_train)
```

Вычисляет стандартное отклонение для пиксельных данных

```
x_train = ((x_train - mean) / std).astype(np.float32)
```

Стандартизация пиксельных данных с использованием среднего значения и стандартного отклонения

4.4 Валидация и переподгонка

В этом разделе демонстрируется случай переподгонки, а затем показан прием обнаружения переподгонки во время тренировки, а также способы решения этой проблемы. Давайте вернемся к смыслу термина «переподгонка». В типичной ситуации в целях повышения точности мы строим все более и более крупные модели. Одним из возможных следствий является то, что модель будет заучивать наизусть некоторые или все примеры. Модель заучивает примеры, вместо того чтобы учиться их обобщать, чтобы точно предсказывать примеры, которые она никогда не встречала во время тренировки. В самом крайнем случае модель может достичь 100%-ной тренировочной точности, но при этом иметь произвольную точность при тестировании (для 10 классов это будет 10%-ная точность).

4.4.1 Валидация

Допустим, тренировка модели занимает несколько часов. Неужели вы хотите ждать до конца тренировки и потом тестировать на тестовых данных, чтобы узнать, что модель была переподогнана? Конечно же нет. Вместо этого мы выделяем небольшую часть тренировочных данных, которые называем *валидационными данными*.

Модель не тренируется с помощью валидационных данных. Вместо этого указанные данные используются после каждой эпохи для оценивания возможного результата на тестовых данных. Как и тестовые данные, валидационные данные пропускаются через модель без обновления модельных параметров (в режиме предсказательного вывода), после чего измеряются потеря и точность. На рис. 4.5 этот процесс показан.

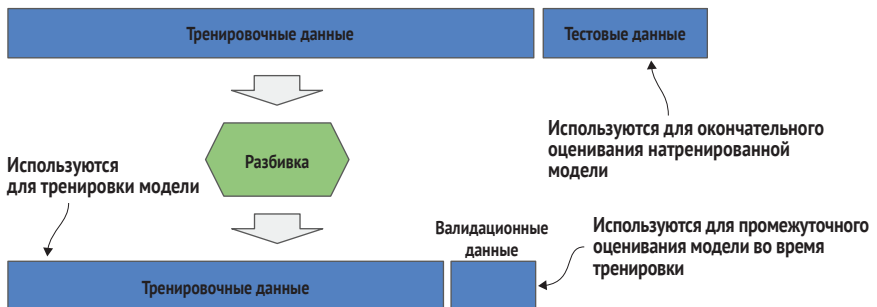


Рис. 4.5 Валидационные данные используются в каждую эпоху для оценивания возможной точности на тестовых данных

Если набор данных очень мал и использование еще меньшего объема данных для тренировки оказывает негативное влияние, то можно применить *перекрестную валидацию*. Вместо того чтобы часть

тренировочных данных, на которых модель никогда не будет тренироваться, с самого начала откладывать в сторону, в каждой эпохе выполняется случайная разбивка. В начале каждой эпохи примеры для валидации отбираются в случайном порядке и не используются для тренировки в этой эпохе, а вместо этого используются для валидационного теста. Но поскольку отбор является случайным, некоторые или все примеры будут появляться среди тренировочных данных в других эпохах. Современные наборы данных имеют крупный размер, поэтому редко можно увидеть необходимость в этой методике. На рис. 4.6 показана разбивка набора данных при перекрестной валидации.




Рис. 4.6 В каждую эпоху для валидационных данных выбирается произвольно отобранный блок

Далее мы натренируем простую сверточную нейросеть классифицировать изображения из набора данных CIFAR-10. Наш набор данных является подмножеством этого набора данных и содержит крошечные изображения размером $32 \times 32 \times 3$. Он состоит из 60 000 тренировочных и 10 000 тестовых изображений, охватывающих 10 классов: самолет, автомобиль, птица, кошка, олень, собака, лягушка, лошадь, корабль и грузовик.

В нашей простой сверточной нейросети есть один сверточный слой из 32 фильтров с размером ядра 3×3 , за которым следует слой пошагового максимального сведения. Затем данные на выходе разглаживаются и передаются в финальный выводящий плотный слой. Рисунок 4.7 иллюстрирует этот процесс.

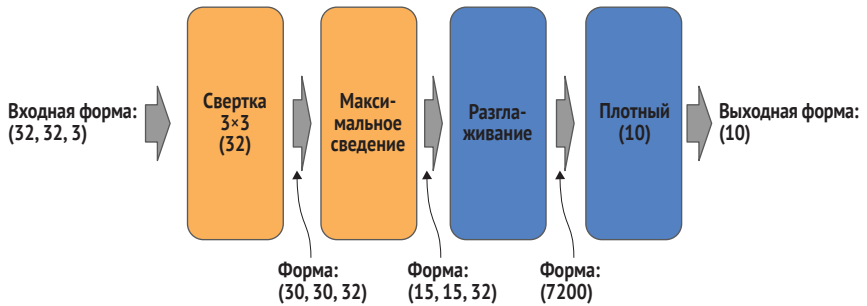


Рис. 4.7 Простая сеть ConvNet для классифицирования изображений CIFAR-10

Ниже приводится исходный код для тренировки простой сверточной нейросети:

```

from tensorflow.keras import Sequential
from tensorflow.keras.layers import Flatten, Dense, Conv2D, MaxPooling2D
import numpy as np

model = Sequential()
model.add(Conv2D(32, (3, 3), activation='relu', input_shape=(32, 32, 3)))
model.add(MaxPooling2D((2, 2)))
model.add(Flatten())
model.add(Dense(10, activation='softmax'))
model.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
              metrics=['acc'])
from tensorflow.keras.datasets import cifar10

(x_train, y_train), (x_test, y_test) = cifar10.load_data()
x_train = (x_train / 255.0).astype(np.float32)
x_test = (x_test / 255.0).astype(np.float32)

model.fit(x_train, y_train, epochs=15, validation_split=0.1)

```

Использует 10 %
тренировочных данных
для валидации – на них
не тренируется

Здесь в метод `fit()` мы добавили именованный параметр `validation_split=0.1`, чтобы после каждой эпохи для валидационного тестирования откладывать 10 % тренировочных данных.

Ниже приведен результат после выполнения 15 эпох. Хорошо видно, что после четвертой эпохи тренировочная и оценочная точности по существу одинаковы. Но после пятой эпохи мы начинаем видеть, как они расходятся (65 % против 61 %). К 15-й эпохе разброс уже очень велик (74 % против 63 %). Примерно в пятую эпоху наша модель явно начала достигать переподгонки:

```

Train on 45000 samples, validate on 5000 samples
...
Epoch 4/15
45000/45000 [=====] - 8s 184us/sample - loss: 1.0444
  - acc: 0.6386 - val_loss: 1.0749 - val_acc: 0.6374

```

После 4-й эпохи точность на тренировочных данных
и валидационных данных примерно одинакова

После 5-й эпохи точность между тренировочными
и валидационными данными начинает расходиться

```
Epoch 5/15
45000/45000 [=====] - 9s 192us/sample - loss: 0.9923
➡ - acc: 0.6587 - val_loss: 1.1099 - val_acc: 0.6182 ←
```

...

```
Epoch 15/15
45000/45000 [=====] - 8s 180us/sample - loss: 0.7256
➡ - acc: 0.7498 - val_loss: 1.1019 - val_acc: 0.6382
```

После 15-й эпохи точность между тренировочными
и валидационными данными далека друг от друга

Теперь давайте поработаем над тем, чтобы модель не достигала слишком большой переподргонки к примерам, а наоборот – могла на них обобщать. Как обсуждалось в предыдущих главах, во время тренировки мы хотим добавлять немного регуляризации – немного шума, – чтобы модель не могла заучивать тренировочные примеры наизусть. В приведенном ниже примере исходного кода мы модифицируем модель за счет добавления 50%-ного отсева перед последним плотным слоем. Поскольку отсев замедлит усвоение (из-за забывания), мы увеличиваем число эпох до 20:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Flatten, Dense, Conv2D
from tensorflow.keras.layers import MaxPooling2D, Dropout
import numpy as np

model = Sequential()
model.add(Conv2D(32, (3, 3), activation='relu', input_shape=(32, 32, 3)))
model.add(MaxPooling2D((2, 2)))
model.add(Flatten(input_shape=(28, 28)))
model.add(Dropout(0.5))
model.add(Dense(10, activation='softmax'))
model.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
              metrics=['acc'])

from tensorflow.keras.datasets import cifar10

(x_train, y_train), (x_test, y_test) = cifar10.load_data()
x_train = (x_train / 255.0).astype(np.float32)
x_test = (x_test / 255.0).astype(np.float32)

model.fit(x_train, y_train, epochs=20, validation_split=0.1)
```

Добавляет шум в тренировку,
чтобы предотвратить переподргонку

Из следующей ниже распечатки мы видим, что хотя для достижения сопоставимой тренировочной точности требуется больше эпох, тренировочная и тестовая точности сопоставимы. Следовательно, модель учится обобщать, а не заучивать тренировочные примеры наизусть:

```
Epoch 18/20
45000/45000 [=====] - 18s 391us/sample - loss:
```

```

➔ 1.0029 - acc: 0.6532 - val_loss: 1.0069 - val_acc: 0.6600
Epoch 19/20
45000/45000 [=====] - 17s 377us/sample - loss:
➔ 0.9975 - acc: 0.6538 - val_loss: 1.0388 - val_acc: 0.6478
Epoch 20/20
45000/45000 [=====] - 17s 381us/sample - loss:
➔ 0.9891 - acc: 0.6568 - val_loss: 1.0562 - val_acc: 0.6502

```

Добавление шума посредством отсева не дает
тренировочной и валидационной точности расходиться

4.4.2 Слежение за потерей

Ранее все наше внимание было сосредоточено на точности. Но на выходе вы увидите еще одну метрику – среднюю по пакетам потерю как для тренировочных данных, так и для оценочных данных. В идеале мы хотели бы видеть неуклонное увеличение точности в расчете на эпоху. Но мы также можем увидеть отрезки эпох, для которых точность выходит на плато или даже колеблется \pm малая величина.

Важно то, что мы видим стабильное снижение потери. Плато или колебания в этом случае происходят из-за того, что мы находимся рядом, или зависаем над линиями линейной разделимости, или не полностью перешли линию, но приближаемся, о чем свидетельствует уменьшение потери.

Давайте посмотрим на это с другой стороны. Допустим, вы создаете классификатор собак и кошек. В классификаторном слое у вас есть два выходных узла: один для кошек и один для собак. Допустим, что в конкретном пакете, когда модель неправильно классифицирует собаку как кошку, выходные значения (уровень уверенности) равны 0.6 для кошки и 0.4 для собаки. В последующем пакете, когда модель снова неправильно классифицирует собаку как кошку, выходные значения равны 0.55 (кошка) и 0.45 (собака). Теперь значения ближе к фундаментальным истинам, и, следовательно, потеря уменьшается, но они все еще не преодолели порог 0.5, поэтому точность пока не изменилась. Затем допустим, что в еще одном последующем пакете выходные значения для изображения собаки равны 0.49 (кошка) и 0.51 (собака); потеря еще больше уменьшилась, и поскольку мы пересекли порог 0.5, точность повысилась.

4.4.3 Погружение вглубь с помощью слоев

Как упоминалось в предыдущих главах, если просто углубляться в слои, то это может привести к нестабильности модели, если только не решать соответствующие проблемы с помощью таких технических приемов, как отождествляющие связи и пакетная нормализация. Например, многие значения, которые мы используем в матричном умножении, являются малыми числами меньше 1. Умножьте два числа меньше 1, и вы получите еще меньшее число. В какой-то мо-

мент числа становятся настолько малыми, что оборудование больше будет неспособно представлять значение. Такая ситуация называется *исчезающим градиентом*. В других случаях параметры могут быть слишком близки, чтобы их можно было друг от друга отличить, или, наоборот, слишком далеки друг от друга. Подобная ситуация называется *взрывающимся градиентом*.

Следующий ниже пример исходного кода это демонстрирует, используя 40-слойную глубокую нейросеть, в которой отсутствуют такие методы защиты от числовой нестабильности по мере углубления в слои, как пакетная нормализация после каждого плотного слоя:

```
model = Sequential()
model.add(Dense(64, activation='relu', input_shape=(28, 28)))
for _ in range(40):
    model.add(Dense(64, activation='relu'))
model.add(Dense(10, activation='softmax'))
model.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
              metrics=['acc'])

from tensorflow.keras.datasets import mnist

(x_train, y_train), (x_test, y_test) = mnist.load_data()
x_train = (x_train / 255.0).astype(np.float32)
x_test = (x_test / 255.0).astype(np.float32)

model.fit(x_train, y_train, epochs=10, validation_split=0.1)
```

В следующей ниже распечатке вы видите, что в первые три эпохи мы имеем неуклонное повышение точности на тренировочных и оценочных данных, а также неуклонное снижение в соответствующей потере. Но впоследствии точность становится неустойчивой, а модель – численно нестабильной:

```

                                     Модельная точность стабильно улучшается
                                     на тренировочных и оценочных данных
Train on 54000 samples, validate on 6000 samples
Epoch 1/10
54000/54000 [=====] - 9s 161us/sample - loss: 1.4461
➡ - acc: 0.4367 - val_loss: 0.8802 - val_acc: 0.7223
Epoch 2/10
54000/54000 [=====] - 7s 134us/sample - loss: 0.8054
➡ - acc: 0.7202 - val_loss: 0.7419 - val_acc: 0.7727
Epoch 3/10
54000/54000 [=====] - 7s 136us/sample - loss: 0.8606
➡ - acc: 0.7530 - val_loss: 0.6923 - val_acc: 0.8352
Epoch 4/10
54000/54000 [=====] - 8s 139us/sample - loss: 0.8743
➡ - acc: 0.7472 - val_loss: 0.7726 - val_acc: 0.7617
Epoch 5/10
54000/54000 [=====] - 8s 139us/sample - loss: 0.7491
```



```

➡ - acc: 0.7863 - val_loss: 0.9322 - val_acc: 0.7165 ←
Epoch 6/10
54000/54000 [=====] - 7s 134us/sample - loss: 0.9151
➡ - acc: 0.7087 - val_loss: 0.8160 - val_acc: 0.7573 ←
Epoch 7/10
54000/54000 [=====] - 7s 135us/sample - loss: 0.9764
➡ - acc: 0.6836 - val_loss: 0.7796 - val_acc: 0.7555 ←
Epoch 8/10
54000/54000 [=====] - 7s 134us/sample - loss: 0.8836
➡ - acc: 0.7202 - val_loss: 0.8348 - val_acc: 0.7382
Epoch 9/10
54000/54000 [=====] - 8s 140us/sample - loss: 0.7975
➡ - acc: 0.7626 - val_loss: 0.7838 - val_acc: 0.7760
Epoch 10/10
54000/54000 [=====] - 8s 140us/sample - loss: 0.7317
➡ - acc: 0.7719 - val_loss: 0.5664 - val_acc: 0.8282

```

Модельная точность становится нестабильной
на тренировочных и оценочных данных

4.5 Схождение

Ранние предположения о тренировке заключались в том, что чем больше раз вводить тренировочные данные в модель, тем выше будет точность. Мы обнаружили, в особенности в более крупных и сложных сетях, что в определенный момент точность будет деградировать. Сегодня мы стремимся достигать схождения на приемлемом локальном оптимуме, основываясь на том, как модель будет использоваться в приложении. Если излишне натренировать нейронную сеть, то может произойти следующее:

- нейронная сеть становится переподогнанной к тренировочным данным, демонстрируя повышенную точность на тренировочных данных, но показывая деградирующую точность на тестовых данных;
- в более глубоких нейронных сетях слои будут учиться неравномерно и иметь разные скорости схождения. Отсюда, поскольку некоторые слои работают в направлении схождения, другие уже могут иметь схождение и, значит, начать расходиться;
- продолжение тренировки может привести к тому, что нейронная сеть выскочит из одного локального оптимума и начнет сходить на другом, менее точном.

На рис. 4.8 показано, что, собственно говоря, мы хотим видеть в идеале при схождении во время тренировки модели. Вы начинаете с довольно быстрого сокращения потери в ранние эпохи и по мере того, как тренировка приближается к (почти) оптимальному... оптимуму, скорость сокращения замедляется, а затем, наконец, выходит на плато – и в этот момент наступает схождение.




Рис. 4.8 Схождение наступает, когда потеря выходит на плато

Давайте начнем с простой модели ConvNet в TF.Keras, чтобы, используя набор данных CIFAR-10, продемонстрировать концепцию схождения, а затем расхождения. В приведенном ниже исходном коде я намеренно опустил методы, которые предотвращают перепогонку, такие как отсев или пакетная нормализация:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D
from tensorflow.keras.layers import Dropout, Flatten, Dense
from tensorflow.keras.datasets import cifar10
from tensorflow.keras.utils import to_categorical
import numpy as np

(x_train, y_train), (x_test, y_test) = cifar10.load_data()
height = x_train.shape[1]
width = x_train.shape[2]

x_train = (x_train / 255.0).astype(np.float32)
x_test = (x_test / 255.0).astype(np.float32)

model = Sequential()
model.add(Conv2D(32, kernel_size=(3, 3),
                 activation='relu',
                 input_shape=(height, width, 3)))
model.add(Conv2D(64, (3, 3), activation='relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Flatten())
model.add(Dense(128, activation='relu'))
model.add(Dense(10, activation='softmax'))
model.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
              metrics=['accuracy'])

model.fit(x_train, y_train, epochs=20, validation_split=0.1)
```

Вычисляет высоту и ширину изображения в наборе данных

Нормализует входные данные

Устанавливает входную форму модели равной высоте и ширине изображений в наборе данных

Ниже приводится статистика за первые шесть эпох. Можно наблюдать неуклонное снижение потери с каждым проходом, то есть нейронная сеть все ближе прилегает к данным. Кроме того, точность на тренировочных данных повышается с 52.35 % до 87.4 %, а на валидационных данных она увеличивается с 63.46 % до 67.14 %:

```

Train on 45000 samples, validate on 5000 samples
Epoch 1/20
45000/45000 [=====] - 53s 1ms/sample - loss: 1.3348
  - acc: 0.5235 - val_loss: 1.0552 - val_acc: 0.6346
Epoch 2/20
45000/45000 [=====] - 52s 1ms/sample - loss: 0.9527
  - acc: 0.6667 - val_loss: 0.9452 - val_acc: 0.6726
Epoch 3/20
45000/45000 [=====] - 52s 1ms/sample - loss: 0.7789
  - acc: 0.7252 - val_loss: 0.9277 - val_acc: 0.6882
Epoch 4/20
45000/45000 [=====] - 419s 9ms/sample - loss: 0.6328
  - acc: 0.7785 - val_loss: 0.9324 - val_acc: 0.6964
Epoch 5/20
45000/45000 [=====] - 53s 1ms/sample - loss: 0.4855
  - acc: 0.8303 - val_loss: 1.0453 - val_acc: 0.6860
Epoch 6/20
45000/45000 [=====] - 51s 1ms/sample - loss: 0.3575
  - acc: 0.8746 - val_loss: 1.2903 - val_acc: 0.6714

```

Первоначальная потеря
на тренировочных данных

Неуклонное снижение на тренировочной потере,
но на валидационной потере есть признаки подгонки к данным

Теперь давайте посмотрим на эпохи с 11 по 20. Хорошо видно, что мы достигли 98.46 % на тренировочных данных, то есть мы плотно ее подогнали. С другой стороны, наша точность на валидационных данных вышла на плато при 66.58 %. Таким образом, после шести эпох непрерывная тренировка не дала никаких улучшений, и можно сделать вывод, что к эпохе 7 модель была переподогнана к тренировочным данным:

```

Epoch 11/20
45000/45000 [=====] - 52s 1ms/sample - loss: 0.0966
  - acc: 0.9669 - val_loss: 2.1891 - val_acc: 0.6694
Epoch 12/20
45000/45000 [=====] - 50s 1ms/sample - loss: 0.0845
  - acc: 0.9712 - val_loss: 2.3046 - val_acc: 0.6666
...
Epoch 20/20
45000/45000 [=====] - 1683s 37ms/sample - loss:
  - acc: 0.9848 - val_loss: 3.1512 - val_acc: 0.6658

```

Валидационная потеря продолжает расти, в то время как модель
становится очень переподогнанной к тренировочным данным

Валидационная потеря очень высока,
и модель плотно подогнана к тренировочным данным

Значения функции потери для тренировочных и валидационных данных также указывают на то, что модель переподогнана. Функция потери между эпохами 11 и 20 на тренировочных данных продолжает уменьшаться, но на соответствующих валидационных данных она выходит на плато, а затем ухудшается (расходится).

4.6 Фиксация контрольных точек и ранняя остановка

В этом разделе рассматриваются два метода повышения экономичности тренировки: фиксация контрольных точек и ранняя остановка. Фиксация контрольных точек полезна, когда модель перетренировывается и расходится и мы хотим восстановить веса модели в точке схождения без дополнительных расходов на перетренировку. Ранняя остановка может рассматриваться как расширение контрольных точек. У нас есть система мониторинга, которая обнаруживает расхождение в самый ранний момент, когда оно происходит, а затем мы прекращаем тренировку, экономя дополнительные расходы во время восстановления контрольной точки в месте расхождения.

4.6.1 Фиксация контрольной точки

Фиксация контрольной точки – это периодическое сохранение модельных параметров, усвоенных во время тренировки, и текущих значений гиперпараметров. Для этого есть две причины:

- иметь возможность возобновлять тренировку модели с того места, на котором вы остановились, вместо того чтобы начинать тренировку с самого начала;
- идентифицировать прошлую точку в тренировке, где модель показала наилучшие результаты.

В первом случае мы, возможно, захотим разбить тренировку на несколько сеансов как способ управления ресурсами. Например, на тренировку мы можем зарезервировать (либо иметь разрешение на) один час в день. В конце одночасовой тренировки результаты тренировки каждый день фиксируются в контрольной точке. На следующий день тренировка возобновляется путем восстановления результатов из контрольной точки. Например, вы можете работать в исследовательской организации с фиксированным бюджетом на вычислительные расходы, и ваш коллектив экспериментирует с тренировкой модели со значительными вычислительными затратами. В целях управления бюджетом вашему коллективу может быть выделен лимит ежедневных вычислительных расходов.

Почему же сохранение модельных весов и смещений не будет достаточным? В нейронных сетях значения некоторых гиперпараметров будут динамически изменяться, например скорость усвоения и затухание. Мы хотели бы возобновлять работу с теми же значениями гиперпараметров, которые имелись на момент приостановки тренировки.

В еще одном сценарии мы могли бы имплементировать непрерывное усвоение как часть процесса непрерывной интеграции и доставки (CI/CD). В этом сценарии в тренировочные данные постоянно добавляются новые помеченные изображения, и мы хотим перетре-

Для моделей с более крупным числом параметров и/или числом эпох мы можем решить сохранять контрольную точку на каждой m -й эпохе с параметром `period`. В следующем ниже примере контрольная точка сохраняется в каждую четвертую эпоху:

```
from tensorflow.keras.callbacks import ModelCheckpoint

filepath = "mymodel-{epoch:02d}.ckpt"
checkpoint = ModelCheckpoint(filepath, period=4)
model.fit(x_train, y_train, epochs=epochs, callbacks=[checkpoint])
```

Создает контрольную точку для каждой четвертой эпохи

В качестве альтернативы можно сохранять текущую наилучшую контрольную точку с параметром `save_best_only=True` и параметром `monitor` для измерения, на котором будет основываться решение. Например, если параметр `monitor` задан равным `val_acc`, то он запишет контрольную точку только в том случае, если валидационная точность выше, чем у последней сохраненной контрольной точки. Если указанный параметр установлен равным `val_loss`, то он запишет контрольную точку только в том случае, если валидационная потеря ниже, чем у последней сохраненной контрольной точки:

Файловый путь для сохранения наилучшей контрольной точки

```
from tensorflow.keras.callbacks import ModelCheckpoint

filepath = "mymodel-best.ckpt"
checkpoint = ModelCheckpoint(filepath, save_best_only=True,
    monitor='val_acc')
model.fit(x_train, y_train, epochs=epochs, callbacks=[checkpoint])
```

Сохраняет контрольную точку только в том случае, если валидационная потеря меньше, чем последняя контрольная точка

4.6.2 Ранняя остановка

Ранняя остановка, или досрочная остановка, – это задание условия, при котором тренировка завершается раньше установленных пределов (например, числа эпох). Обычно это делается с целью экономии ресурсов и/или предотвращения перетренированности, когда целевой критерий достигнут, такой как уровень точности или схождение на оценочной потере. Например, мы могли бы проводить тренировку в течение 20 эпох, продолжительностью в среднем 30 минут каждая, в общей сложности в течение 10 часов. Но если критерий будет достигнут через 8 эпох, то было бы идеально завершить тренировку, сэкономив 6 часов ресурсов.

Ранняя остановка задается в ключе, аналогичном контрольной точке. Объект `EarlyStopping` инстанцируется и конфигурируется с целевым критерием и передается параметру `callbacks` метода `fit()`. В приведенном ниже примере тренировка будет остановлена

досрочно только в том случае, если валидационная потеря перестанет уменьшаться по сравнению с предыдущей эпохой:

```

Импортирует класс EarlyStopping
→ from tensorflow.keras.callbacks import EarlyStopping
Устанавливает раннюю остановку,
когда валидационная потеря
перестала уменьшаться
earlystop = EarlyStopping(monitor='val_loss')

→ model.fit(x_train, y_train, epochs=epochs, callbacks=[earlystop])
Тренирует модель и использует раннюю остановку, чтобы остановить
тренировку досрочно, если валидационная потеря перестает уменьшаться

```

В дополнение к мониторингу валидационной потери для ранней остановки можно отслеживать валидационную точность. Это делается с помощью параметрической настройки `monitor="val_acc"`. Для точной регулировки существуют дополнительные параметры, чтобы предотвращать непреднамеренную раннюю остановку; например, когда застревание в седловой точке – участке плато на кривой потери – преодолевается большим числом тренировок. Параметр `patience` задает минимальное число эпох, не имевших улучшений, перед ранней остановкой, а `min_delta` задает минимальный порог для решения о том, что модель улучшилась. В приведенном ниже примере тренировка будет остановлена досрочно, если после трех эпох не произойдет улучшения в валидационной потере:

```

Устанавливает раннюю остановку, когда валидационная
потеря перестала уменьшаться в течение трех эпох
from tensorflow.keras.callbacks import EarlyStopping

earlystop = EarlyStopping(monitor='val_loss', patience=3)
model.fit(x_train, y_train, epochs=epochs, callbacks=[earlystop])

```

4.7 Гиперпараметры

Давайте начнем с объяснения разницы между усваиваемыми параметрами и гиперпараметрами. Усваиваемые параметры, веса и смещения, заучиваются во время тренировки. Для нейронных сетей это, как правило, веса на каждом нейросетевом соединении и смещения на каждом узле. Для сверточной нейросети усваиваемыми параметрами являются фильтры в каждом сверточном слое. Эти усваиваемые параметры остаются частью модели, когда модель закончит проходить тренировку.

Гиперпараметры – это параметры, используемые для тренировки модели, но не являющиеся частью самой натренированной модели. После тренировки гиперпараметры больше не существуют. Гиперпараметры используются для улучшения процесса тренировки модели, отвечая на такие вопросы, как:

- сколько времени требуется для тренировки модели?
- как быстро модель сходится?
- находит ли она глобальный оптимум?
- насколько точной является модель?
- насколько переподогнанной является модель?

Еще одна точка зрения на гиперпараметры состоит в том, что они являются средством измерения стоимости и качества разработки модели. Мы будем углубляться в эти и другие вопросы по мере дальнейшего разведывания темы гиперпараметров в главе 10.

4.7.1 Эпохи

Самым базовым гиперпараметром является число эпох, хотя в настоящее время этот гиперпараметр чаще заменяют шагами. Гиперпараметр *эпох* – это число раз, которое вы будете пропускать все тренировочные данные через нейронную сеть во время тренировки.

Тренировка обходится очень дорого с точки зрения вычислительного времени. Сюда входит и пропускание тренировочных данных через сеть в прямом направлении, и обратное распространение с целью обновления (тренировки) модельных параметров. Например, если полный проход данных (эпоха) занимает 15 минут, а мы выполняем 100 эпох, то время тренировки составит 25 часов.

4.7.2 Шаги

Есть и еще один способ повысить точность и сократить время тренировки, а именно путем изменения выборочного распределения тренировочного набора данных. В случае эпох мы думаем о последовательном извлечении пакетов из тренировочных данных. Несмотря на то что мы случайно перетасовываем тренировочные данные в начале каждой эпохи, выборочное распределение остается прежним.

Теперь давайте подумаем обо всей популяции предмета, который мы хотим распознавать. В статистике мы называем это *распределение популяционным* (рис. 4.9).

Но у нас никогда не будет набора данных, отражающего фактическое популяционное распределение в целом. Вместо него у нас есть выборки, которые мы называем *выборочным распределением популяционного распределения* (рис. 4.10).

Улучшить модель можно еще одним способом – путем дополнительного заучивания наилучшего выборочного распределения для тренировки модели. Хотя наш набор данных, возможно, будет фиксированным, можно использовать несколько методов, чтобы его изменить и, таким образом, усваивать выборочное распределение, которое подходит для тренировки модели лучше всего. Эти методы таковы:

- регуляризация/отсев;
- пакетная нормализация;
- обогащение (аугментация) данных.

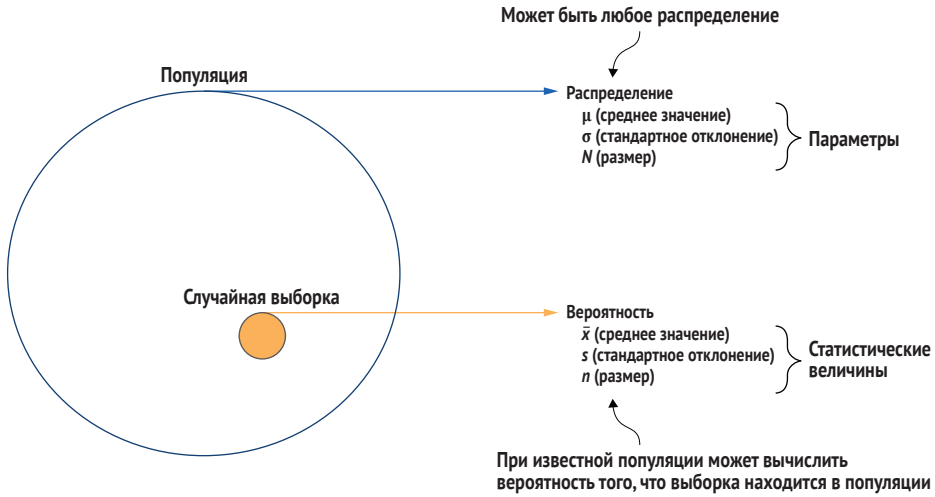


Рис. 4.9 Разница между популяционным распределением и случайной выборкой изнутри популяции

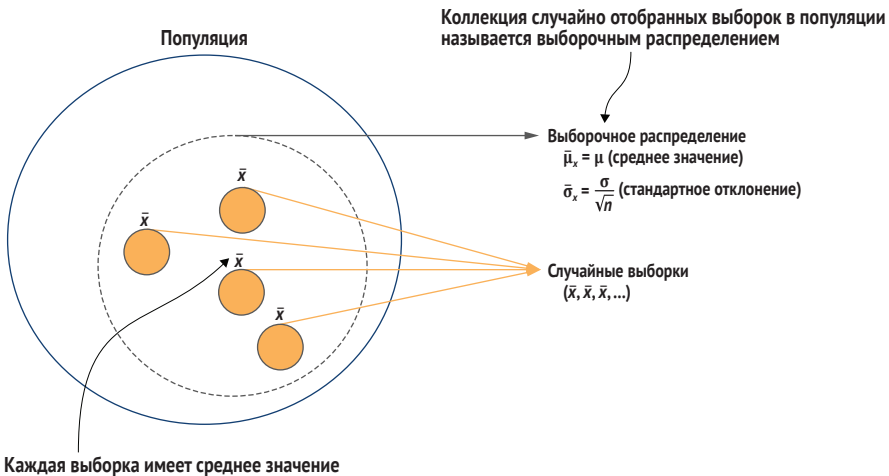


Рис. 4.10 Выборочное распределение состоит из случайных выборок из популяции

С этой точки зрения мы больше не рассматриваем подачу данных в нейронную сеть как последовательный проход по тренировочным данным, а смотрим на него как на случайный отбор из выборочного распределения. В таком контексте *шаги* относятся к числу пакетов (извлечений), которые мы будем делать из выборочного распределения тренировочных данных.

При добавлении в нейронные сети слоев отсева мы отсеиваем активации случайно на основе каждой выборки. В дополнение к уменьшению перепогонки нейронной сети мы также изменяем распределение.

С помощью пакетной нормализации мы минимизируем ковариантный сдвиг между пакетами тренировочных данных (выборок). Активации перешкалируются с помощью стандартизации, используемой подобно тому, как она применяется на входных данных (мы вычитаем среднее значение пакета и делим на стандартное отклонение пакета). Такая нормализация уменьшает колебания в обновлениях модельных параметров; указанный процесс называется *добавлением стабильности в тренировку*. Вдобавок такая нормализация имитирует извлечение из выборочного распределения, представляющего популяционное распределение шире.

С помощью обогащения данных (обсуждается в главе 13) мы создаем новые примеры, модифицируя существующие примеры в рамках набора параметров. Затем случайно отбираем модификацию, которая также способствует изменению распределения.

С помощью пакетной нормализации, регуляризации/отсева и обогащения данных никакие две эпохи не будут иметь одинаковое выборочное распределение. В этом случае на практике в настоящее время принято лимитировать число случайных извлечений (шагов) из каждого нового выборочного распределения, дополнительно изменяя распределение. Например, если шаги заданы в размере 1000, то за эпоху будет отбираться и подаваться в нейронную сеть для тренировки только 1000 случайных пакетов.

В TF.Keras можно указывать число эпох и число шагов в качестве параметров метода `fit()`, как параметры `epochs` и `steps_per_epoch`:

```
model.fit(x_train, y_train, batch_size=batch_size, epochs=epochs,  
         steps_per_epoch=1000)
```

4.7.3 Размер пакета

В целях понимания того, как устанавливать размер пакета, необходимо иметь базовое представление о трех типах алгоритмов градиентного спуска: стохастическом градиентном спуске, пакетном градиентном спуске и мини-пакетном градиентном спуске. Алгоритм – это средство, с помощью которого модельные параметры обновляются (усваиваются моделью) во время тренировки.

СТОХАСТИЧЕСКИЙ ГРАДИЕНТНЫЙ СПУСК

В *стохастическом градиентном спуске* (stochastic gradient descent, аббр. SGD) модель обновляется после подачи каждого примера во время тренировки. Поскольку каждый пример отбирается случайно, дисперсия между примерами может приводить к крупным колебаниям градиента.

Его преимущество заключается в том, что во время тренировки мы с большей вероятностью сойдемся на локальном (то есть меньшем) оптимуме и с большей вероятностью найдем глобальный оптимум для схождения. Еще одна выгода заключается в том, что темп изме-

нения в потере можно отслеживать в реальном времени, что помогает в алгоритмах автоматической гиперпараметрической настройки. Его недостатком является то, что он вычислительно затратнее в расчете на эпоху.

ПАКЕТНЫЙ ГРАДИЕНТНЫЙ СПУСК

В *пакетном градиентном спуске* потеря (квадратической) ошибки в расчете на пример рассчитывается по мере подачи каждого примера во время тренировки, но обновление модели выполняется в конце каждой эпохи (после пропуска всех тренировочных данных через сеть). В результате градиент сглаживается, потому что он рассчитывается по потере всех примеров, а не одного примера.

Его преимущества заключаются в том, что он менее вычислительно затратен в расчете на эпоху, и тренировка сходится надежнее. Его недостатками является то, что модель может сходиться к менее точному локальному оптимуму, и для мониторинга данных о производительности необходимо выполнять всю эпоху целиком.

МИНИ-ПАКЕТНЫЙ ГРАДИЕНТНЫЙ СПУСК

Метод *мини-пакетного градиентного спуска* представляет собой компромисс между стохастическим и пакетным градиентным спусками. Вместо одного примера или всех примеров нейронная сеть получает данные мини-пакетами, то есть подмножеством всех тренировочных данных. Чем меньше мини-пакетная сторона, тем больше тренировка будет напоминать стохастический градиентный спуск, тогда как более крупные размеры пакета будут напоминать пакетный градиентный спуск.

Для определенных моделей и наборов данных стохастический градиентный спуск работает лучше всего. В общем случае на практике принято использовать компромисс, предлагаемый мини-пакетным градиентным спуском. Гиперпараметр `batch_size` задает размер мини-пакета. Из-за аппаратной архитектуры наиболее эффективные по времени и пространству размеры пакетов кратны 8, например 8, 16, 32 и 64. Размер пакета, который пробуется чаще всего в начале, равен 32, а затем 128. Для чрезвычайно крупных наборов данных на аппаратных ускорителях более высокого класса (таких как графические и тензорные процессоры) обычно используются пакеты размером 256 и 512. В `TF.Keras` размер пакета можно указать в модельном методе `fit()`:

```
model.fit(x_train, y_train, batch_size=32)
```

4.7.4 Скорость усвоения

Скорость усвоения традиционно является наиболее влиятельным из гиперпараметров. Она может оказывать существенное влияние на продолжительность тренировки нейронной сети, а также на ее схо-

димось к локальному (меньшему) оптимуму и к глобальному (наилучшему) оптимуму.

При обновлении модельных параметров во время прохода методом обратного распространения алгоритм градиентного спуска используется для выведения из функции потери этого прохода значения, которое следует прибавить/вычесть из модельных параметров. Эти сложения и вычитания могут приводить к крупным колебаниям значений параметров. Если модель имеет и продолжает иметь крупные колебания значений параметров, то модельные параметры будут «разбросаны повсюду» и никогда не сойдутся.

Если вы наблюдаете большие колебания в размере потери и/или точности, то тренировка вашей модели не сходится. Если тренировка не сходится, то не важно, сколько эпох вы выполняете; модель никогда не закончит тренировку.

Скорость усвоения дает возможность контролировать степень обновления параметров модели. В базовом методе скорость усвоения представляет собой фиксированный коэффициент от 0 до 1, который умножается на прибавляемое/вычитаемое значение, чтобы уменьшить добавляемую или вычитаемую величину. Эти меньшие приращения повышают стабильность во время тренировки и увеличивают возможность схождения.

Малая скорость усвоения против крупной

Если использовать очень малую скорость усвоения, к примеру 0.001, то во время обновлений мы исключим большие колебания модельных параметров. Это, как правило, будет гарантировать, что тренировка будет сходиться на локальном оптимуме. Но есть и недостаток. Во-первых, чем меньше мы делаем приращения, тем больше проходов по тренировочным данным (эпохам) потребуется, чтобы минимизировать потерю. Это означает больше времени на тренировку. Во-вторых, чем меньше приращения, тем меньше вероятность того, что тренировка будет разведывать другие локальные оптимумы, которые могут быть точнее, чем тот, на котором сходится тренировка; вместо этого она может сойтись на слабом локальном оптимуме либо застрять в седловой точке.

Крупная скорость усвоения, к примеру 0.1, вероятно, будет во время обновлений вызывать большие скачки модельных параметров. В некоторых случаях это может первоначально привести к более быстрому схождению (меньшему числу эпох). Ее недостатком является то, что даже если вы будете сходиться изначально быстро, скачки могут превысить скорость и начать приводить к тому, что схождение будет колебаться взад и вперед или перепрыгивать через разные локальные оптимумы. При очень высоких скоростях усвоения тренировка может начать расходиться (увеличивая потерю).

Многочисленные факторы помогают определять величину наилучшей скорости усвоения в разное время в течение тренировки. Как показывают лучшие образцы практики, скорость будет варьироваться от $10e-5$ до 0.1.

Ниже приведена базовая формула, которая корректирует вес путем умножения скорости усвоения на величину, рассчитанную для прибавления/вычитания (градиент):

```
weight += -learning_rate * gradient
```

Затухание

На практике было принято начинать с немного более крупной скорости усвоения, а затем постепенно ее снижать. Такое снижение также называется *затуханием скорости усвоения*. Более высокая скорость усвоения сначала позволила бы разведывать разные локальные оптимумы, на которых можно было бы сходиться, и делать первоначальные глубокие витки в соответствующие локальные оптимумы. Для того чтобы концентрироваться на наилучшем (хорошем) локальном оптимуме, на первоначальных обновлениях нередко используется скорость схождения и минимизация функции потери.

С того момента скорость усвоения постепенно затухает. По мере затухания скорости усвоения вероятность колебаний за пределы хорошего локального оптимума снижается, и неуклонно снижающаяся скорость усвоения будет настраивать схождение на приближение к минимальной точке (хотя все меньшая и меньшая скорость усвоения будет увеличивать время тренировки). Таким образом, затухание становится компромиссом между малыми увеличениями окончательной точности и совокупным временем тренировки.

Ниже приведена базовая формула, добавляющая затухание к расчету обновления весов. При каждом обновлении скорость усвоения уменьшается на величину затухания (именуемую *фиксированным затуханием*):

```
weight += -learning_rate * gradient
learning_rate -= decay
```

На практике формулы затухания традиционно основаны на времени, на шаге либо на косинусе. Эти формулы могут выражаться упрощенно, и итерация может быть пакетом либо эпохой. В оптимизаторах TF.Keras по умолчанию используется затухание на основе времени. Формулы таковы:

- затухание на основе времени:

```
learning_rate *= (1 / (1 + decay * iteration))
```

- затухание на основе шага:

```
learning_rate = initial_learning_rate * decay**iteration
```

- затухание на основе косинуса:

```
learning_rate = c * (1 + cos(pi * (steps_per_epoch * interaction)/epochs))
# где c обычно находится в диапазоне от 0.45 до 0.55
```

Моментум

Еще одной распространенной практикой является ускорение либо замедление темпов изменений, основываясь на предыдущих изменениях. Если у нас в сходимости будут большие скачки, то мы рискуем выскочить за пределы локального оптимума, поэтому может потребоваться замедлить скорость усвоения. Если в сходимости есть малые или нулевые изменения, то мы, возможно, захотим увеличить скорость усвоения, чтобы перепрыгнуть через седловую точку. Как правило, значения моментума (импульса) варьируются от 0.5 до 0.99:

```
velocity = (momentum * velocity) - (learning_rate * gradient)
weight += velocity
```

Адаптивная скорость усвоения

Многие популярные алгоритмы адаптируют скорость усвоения динамически:

- Adadelta;
- Adagrad;
- Adam;
- AdaMax;
- AMSGrad;
- Momentum;
- Nadam;
- Nesterov;
- RMSprop.

Объяснение этих алгоритмов выходит за рамки данного раздела. Для получения дополнительной информации об этих и других оптимизаторах см. документацию по `tf.keras.optimizers` (<http://mng.bz/Par9>). В `TF.Keras` эти алгоритмы скорости усвоения задаются, когда для минимизирования функции потерь определен оптимизатор:

```
from tensorflow.keras import optimizers

optimizer = optimizers.RMSprop(lr=0.001, rho=0.9, epsilon=None, decay=0.0)
model.compile(loss='mean_squared_error', optimizer=optimizer)
```

Задаёт скорость усвоения
и затухание для оптимизатора

Компилирует модель, задавая функцию потерь и оптимизатор

4.8 Инвариантность

Так что же такое *инвариантность*? В контексте нейронных сетей она означает, что если преобразовать входное значение, то результат (предсказание) останется неизменным. В контексте тренировки классификатора изображений для тренировки модели распознавать объект независимо от размера и местоположения объекта на изображении без необходимости в дополнительных тренировочных данных может использоваться обогащение изображений.

Давайте рассмотрим сверточную нейросеть – классификатор изображений (эта аналогия также может быть применена и к обнаружению объектов). Мы хотим, чтобы классифицируемый объект распознавался правильно независимо от его местоположения на изображении. Если преобразовать входные данные и вследствие этого преобразования объект будет сдвинут в новое место на изображении, то мы хотим, чтобы результат (предсказание) оставался неизменным.

Для сверточных нейросетей и изображений в целом основными типами инвариантности, которые мы хотим поддерживать в модели, являются *трансляционная* и *масштабная* инвариантности. До 2019 года трансляционная и масштабная инвариантности управлялись вышестоящим обрабатывающим потоком, связанным с обогащением изображений в рамках тренировки модели, используя предобработку на CPU, в то время как данные подавались во время тренировки на GPU. Мы обсудим эти традиционные методы в данном разделе.

Один из подходов к тренировке под трансляционную/масштабную инвариантность состоит в том, чтобы просто иметь достаточное число изображений по каждому классу (каждому объекту), дабы объект находился на изображении в разных местах, разных поворотах, разных масштабах и разных ракурсах. Собирать все эти вариации, пожалуй, не совсем непрактично.

Оказывается, существует простой метод автоматического генерирования инвариантных к трансляции/масштабу изображений с использованием предобработки путем обогащения изображения, которая эффективно выполняется с применением матричных операций. Матрично-ориентированные преобразования могут выполняться разными пакетами Python, такими как класс `ImageDataGenerator` модуля `TF.Keras`, модуль `tf.image` каркаса TensorFlow или библиотека `OpenCV`.

На рис. 4.11 показан типичный конвейер обогащения изображения при подаче тренировочных данных в модель. В каждом извлеченном пакете отбирается случайное подмножество изображений, которые необходимо обогатить (например, 50 %). Затем это случай-

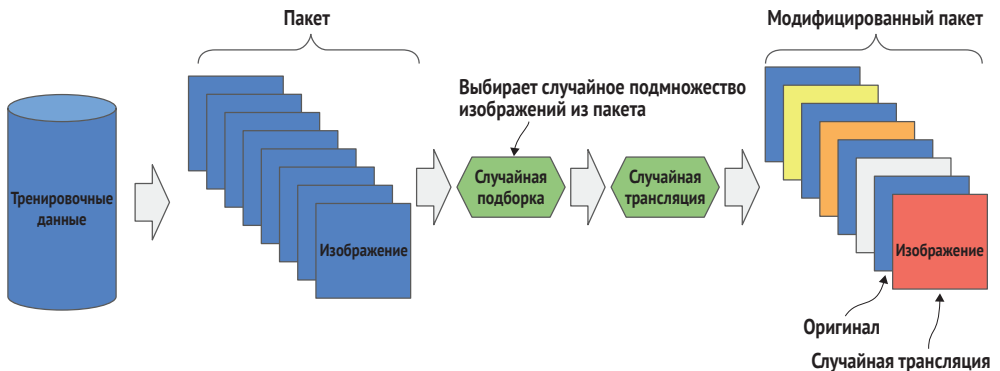


Рис. 4.11 Во время обогащения изображений насыщается подмножество изображений, которые были случайно отобраны в пакете

но отобранное подмножество изображений случайно преобразовывается в соответствии с определенными ограничениями, такими как случайно отобранное значение поворота от -30° до 30° . Модифицированный пакет (оригиналы плюс обогащенные) затем подается в модель для тренировки.

4.8.1 Трансляционная инвариантность

В этом подразделе описывается способ обогащения изображения в ручном режиме в тренировочном наборе данных таким образом, чтобы модель училась распознавать объект независимо от его местоположения на изображении. Например, мы хотим, чтобы модель распознавала лошадь независимо от того, в каком направлении лошадь повернута на изображении, или яблоко независимо от того, где оно расположено на заднем плане.

Трансляционная инвариантность в контексте ввода изображения включает следующее:

- вертикальное/горизонтальное расположение (объект может находиться в любом месте изображения);
- поворот (объект может быть повернут в любую сторону).

Вертикальное/горизонтальное преобразование обычно выполняется либо как операция циклического сдвига матрицы, либо как обрезка. Ориентация (например, зеркальная) обычно выполняется как переворот матрицы, а поворот – как транспонирование матрицы.

ПЕРЕВОРОТ

Матричный переворот преобразовывает изображение, переворачивая его либо по вертикальной, либо по горизонтальной оси. Поскольку изображение представлено в виде стопки 2-мерных матриц (по одной на канал), переворот может эффективно выполняться в виде функции транспонирования матрицы без изменений (таких как интерполяция) пиксельных данных. На рис. 4.12 сравниваются изначальная и перевернутая версии изображения.



Рис. 4.12 Сравнение яблока: оригинал, перевороты по вертикальной и горизонтальной осям (источник изображения: malerapaso, iStock)

Давайте начнем с того, что покажем, как перевернуть изображение с помощью популярных библиотек Python по обработке изображений. Следующий ниже фрагмент исходного кода демонстрирует переверот изображения по вертикали (зеркально) и по горизонтали с помощью метода транспонирования матрицы в библиотеке методов обработки изображений PIL:

```
from PIL import Image

image = Image.open('apple.jpg')  ← Читает изображение в память

image.show()  ← Выводит изображение на экран в изначальном ракурсе

flip = image.transpose(Image.FLIP_LEFT_RIGHT)
flip.show()

flip = image.transpose(Image.FLIP_TOP_BOTTOM)
flip.show()
```

Переворачивает изображение по вертикальной оси (зеркальное отражение)

Переворачивает изображение по горизонтальной оси (вверх тормашками)

В качестве альтернативы перевероты можно выполнять с помощью модуля ImageOps библиотеки PIL, как продемонстрировано ниже:

```
from PIL import Image, ImageOps

image = Image.open('apple.jpg')  ← Читает изображение в память

flip = ImageOps.mirror(image)
flip.show()

flip = ImageOps.flip(image)
flip.show()
```

Переворачивает изображение по вертикальной оси (зеркальное отражение)

Переворачивает изображение по горизонтальной оси (вверх тормашками)

Следующий ниже фрагмент исходного кода демонстрирует переверот изображения вертикально (зеркально) и горизонтально, используя метод транспонирования матрицы в библиотеке OpenCV:

```
import cv2
from matplotlib import pyplot as plt

image = cv2.imread('apple.jpg')

plt.imshow(image)  ← Выводит изображение на экран в изначальном ракурсе

flip = cv2.flip(image, 1)
plt.imshow(flip)

flip = cv2.flip(image, 0)
plt.imshow(flip)
```

Переворачивает изображение по вертикальной оси (зеркальное отражение)

Переворачивает изображение по горизонтальной оси (вверх тормашками)

Приведенный ниже исходный код демонстрирует переворот изображения по вертикальной оси (зеркально) и по горизонтальной оси с помощью метода транспонирования матрицы из библиотеки NumPy:

```
import numpy as np
import cv2
from matplotlib import pyplot as plt
```

```
image = cv2.imread('apple.jpg')
```

```
plt.imshow(image)
```

```
flip = np.flip(image, 1)
```

```
plt.imshow(flip)
```

Переворачивает изображение
по вертикальной оси
(зеркальное отражение)

```
flip = np.flip(image, 0)
```

```
plt.imshow(flip)
```

Переворачивает изображение по горизонтальной оси (вверх тормашками)

Поворот 90/180/270

В дополнение к переворотам операция транспонирования матрицы может использоваться для поворота изображения на 90° (влево), 180° и 270° (вправо). Как и переворот, эта операция является эффективной, не требует интерполяции пикселей и не имеет побочного эффекта обрезания. На рис. 4.13 сравниваются изначальная версия и версия с поворотом на 90°.




Рис. 4.13 Сравнение яблока: поворот на 90°, 180° и 270°

Приведенный ниже фрагмент исходного кода демонстрирует поворот изображения на 90°, 180° и 270° с помощью метода транспонирования матрицы из библиотеки методов обработки изображений PIL языка Python:

```
from PIL import Image
```

```
image = Image.open('apple.jpg')
```

```
rotate = image.transpose(Image.ROTATE_90)
```

```
rotate.show()
```

Поворачивает
изображение на 90°

<code>rotate = image.transpose(Image.ROTATE_180)</code> <code>rotate.show()</code>	Поворачивает изображение на 180°
<code>rotate = image.transpose(Image.ROTATE_270)</code> <code>rotate.show()</code>	Поворачивает изображение на 270°

В библиотеке OpenCV нет метода транспонирования на 90° либо 270°; поворот на 180° можно делать, используя метод переворота со значением `-1`. (Все другие повороты с использованием OpenCV показаны в следующем подразделе с применением модуля `imutils`.)

```
import cv2
from matplotlib import pyplot as plt

image = cv2.imread('apple.jpg')

rotate = cv2.flip(image, -1)
plt.imshow(rotate)
```

	Поворачивает изображение на 180°
--	-------------------------------------

В следующем ниже примере показан поворот изображения на 90°, 180° и 270° с помощью метода `rot90()` из библиотеки NumPy, первым параметром которого является изображение для поворота на 90°, а вторым параметром (`k`) – число поворотов, которые необходимо выполнить:

```
import numpy as np
import cv2
from matplotlib import pyplot as plt

image = cv2.imread('apple.jpg')

rotate = np.rot90(image, 1)
plt.imshow(rotate)
```

	Поворачивает изображение на 90°
--	------------------------------------

```
rotate = np.rot90(image, 2)
plt.imshow(rotate)
```

	Поворачивает изображение на 180°
--	-------------------------------------

```
rotate = np.rot90(image, 3)
plt.imshow(rotate)
```

	Поворачивает изображение на 270°
--	-------------------------------------

При переворачивании изображения на 90° или 270° вы меняете ориентацию изображения, что не является проблемой, если высота и ширина изображения одинаковы. Если нет, то высота и ширина будут транспонированы в повернутом изображении и не будут совпадать с входным вектором нейронной сети. В этом случае следует использовать модуль `imutils` или другие средства для изменения размера изображения.

ПОВОРОТ

Поворот преобразовывает изображение, поворачивая его в пределах -180° и 180° . Как правило, градус поворота выбирается случайно.

Вы также можете ограничивать диапазон поворота, чтобы он соответствовал среде, в которой будет развернута модель. Вот несколько подходов, распространенных на практике:

- если изображения будут четкими, то использовать диапазон от -15° до 15° ;
- если изображения могут быть наклонены, то использовать диапазон от -30° до 30° ;
- для малых предметов, таких как пакеты или деньги, использовать полный диапазон от -180° до 180° .

Еще одна трудность с поворотом заключается в том, что при повороте изображения в пределах границ того же размера, отличном от 90° , 180° или 270° , часть края изображения окажется за пределами границы (обрезанная).

На рис. 4.14 приведен пример использования метода `rotate()` библиотеки PIL для поворота изображения яблока на 45° . Вы видите, что низ яблока и лист обрезаны.



Рис. 4.14 Пример обрезки изображения при повороте, не кратном 90°

Правильный способ обработки поворота состоит в его повороте внутри крупной ограничивающей области, чтобы никакая часть изображения не была обрезана, а затем изменении размера повернутого изображения до его изначального размера. Для этой цели я рекомендую использовать модуль `imutils` (созданный Адрианом Розброком, <http://mng.bz/jvR0>), который состоит из коллекции удобных методов для библиотеки OpenCV:

```
import cv2, imutils
from matplotlib import pyplot as plt

image = cv2.imread('apple.jpg')
shape = (image.shape[0], image.shape[1])
rotate = imutils.rotate_bound(image, 45)
rotate = cv2.resize(rotate, shape, interpolation=cv2.INTER_AREA)
plt.imshow(rotate)
```

Запоминает изначальные высоту и ширину

Поворачивает изображение

Возвращает размер изображения назад к изначальному

Сдвиг

Сдвиг перемещает пиксельные данные на изображении \pm по вертикальной (высоте) или горизонтальной (ширине) оси. Он изменяет местоположение классифицируемого объекта на изображении. На рис. 4.15 показано изображение яблока, сдвинутое вниз на 10 % и вверх на 10 %.



Рис. 4.15 Сравнение яблока: оригинал, сдвиг на 10 % вниз, сдвиг на 10 % вверх

Следующий ниже фрагмент исходного кода демонстрирует сдвиг изображения $\pm 10\%$ по вертикали и горизонтали с помощью метода `np.roll()` библиотеки NumPy:

```
import cv2
import numpy as np
from matplotlib import pyplot as plt

image = cv2.imread('apple.jpg')

height = image.shape[0]
width = image.shape[1] | Получает высоту и ширину изображения

roll = np.roll(image, height // 10, axis=0)
plt.imshow(roll) | Сдвигает изображение вниз на 10 %

roll = np.roll(image, -(height // 10), axis=0)
plt.imshow(roll) | Сдвигает изображение вверх на 10 %

roll = np.roll(image, width // 10, axis=1)
plt.imshow(roll) | Сдвигает изображение вправо на 10 %

roll = np.roll(image, -(width // 10), axis=1)
plt.imshow(roll) | Сдвигает изображение влево на 10 %
```

Сдвиг эффективен тем, что он имплементирован в виде операции циклического сдвига матрицы (`roll`); сдвигаются строки (высота) или столбцы (ширина). В силу этого пиксели, сдвинутые с конца, добавляются в начало.

Если сдвиг слишком большой, то изображение может раздробиться на две части, каждая из которых будет противоположна другой. На

рис. 4.16 показано яблоко, сдвинутое на 50 % по вертикали, в результате чего оно разломилось на две части.




Рис. 14.16 Когда изображение сдвигается слишком сильно, оно становится раздробленным на две части

Во избежание дроблений на практике традиционно принято ограничивать сдвиг изображения не более чем на 20 %. В качестве альтернативы можно было бы изображение обрезать и заполнить обрезанное пространство черной подушкой, как показано ниже с помощью библиотеки OpenCV:

```
import cv2
from matplotlib import pyplot as plt

image = cv2.imread('apple.png')
image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)

height = image.shape[0]
width = image.shape[1]

image = image[0: height//2, :, :]
image = cv2.copyMakeBorder(image, (height//4), (height//4), 0, 0,
                           cv2.BORDER_CONSTANT, 0)
plt.imshow(image)
```

Получает высоту изображения

Отбрасывает нижнюю часть (50 %) изображения

Делает черную рамку, чтобы восстановить изображение до его изначального размера

Приведенный выше исходный код генерирует результат, показанный на рис. 4.17.




Рис. 4.17 Использование обрезки и заливки во избежание дроблений изображений на части

4.8.2 Масштабная инвариантность

В этом подразделе описывается способ обогащения изображения в ручном режиме в тренировочном наборе данных, в частности чтобы модель научилась распознавать объект на изображении независимо от размера объекта. Например, мы хотим, чтобы модель распознавала яблоко независимо от занимаемой им части изображения либо от того, что оно является малой частью изображения, наложенного на фон.

Масштабная инвариантность в контексте ввода изображения включает следующее:

- масштабирование (на изображении объект может иметь любой размер);
- аффинность (объект можно рассматривать с любой точки зрения).

ИЗМЕНЕНИЕ МАСШТАБА

Масштабирование, или зумирование, преобразовывает изображение, изменяя масштаб от центра изображения, что выполняется с помощью операции «изменить размер и обрезать». Вы отыскиваете центр изображения, вычисляете ограничивающую рамку вокруг центра, а затем обрезаете изображение. На рис. 4.18 показано изображение яблока, увеличенное в масштабе в 2 раза.



Рис. 4.18 Изображение обрезается после изменения масштаба, чтобы сохранить тот же размер изображения

При увеличении размера изображения с помощью `Image.resize()` наилучшие результаты обычно обеспечиваются интерполяцией `Image.BICUBIC`. Приведенный ниже фрагмент исходного кода демонстрирует то, как увеличивать масштаб изображения с помощью библиотеки методов обработки изображений PIL на языке Python:

```
from PIL import Image
image = Image.open('apple.jpg')

zoom = 2
height, width = image.size

image = image.resize( (int(height*zoom),
                      int(width*zoom)), Image.BICUBIC)
```

Запоминает изначальную
высоту, ширину изображения

Изменяет размер (масштабирует)
изображение пропорционально масштабу

```

center = (image.size[0]//2, image.size[1]//2) ← Отыскивает центр
                                                масштабированного изображения
crop = (int(center[0]//zoom), int(center[1]//zoom))
box = ( crop[0], crop[1], (center[0] + crop[0]), (center[1] + crop[1]) ) ← Вычисляет
Вычисляет верхний левый угол обрезки                                ограничивающий
                                                                    прямоугольник обрезки
image = image.crop( box ) ← Обрезает изображение
image.show()

```

В следующем ниже примере исходного кода показано увеличение масштаба изображения с помощью библиотеки методов обработки изображений OpenCV. При увеличении изображения с помощью интерполяции `cv2.resize()` наилучшие результаты обычно обеспечиваются интерполяцией `cv2.INTER_CUBIC`. Интерполяция `cv2.INTER_LINEAR` работает быстрее и обеспечивает почти сопоставимые результаты. Интерполяция `cv2.INTER_AREA` обычно используется при уменьшении изображения.

```

import cv2
from matplotlib import pyplot as plt

zoom = 2

height, width = image.shape[:2] ← Запоминает изначальную высоту, ширину

center = (image.shape[0]//2, image.shape[1]//2)
z_height = int(height // zoom)
z_width = int(width // zoom)
image = image[(center[0] - z_height//2):(center[0] + z_height//2), center[1] -
              z_width//2:(center[1] + z_width//2)] ← Отыскивает центр
                                                    масштабированного изображения

image = cv2.resize(image, (width, height), interpolation=cv2.INTER_CUBIC)
plt.imshow(image)
Изменяет размер (увеличивает) обрезанное изображение,
возвращаясь к изначальному размеру
Обрезает (вырезает) масштабированное
изображение, формируя
ограничивающую рамку обрезки

```

4.8.3 ImageDataGenerator модуля TF.Keras

Модуль предобработки изображений TF.Keras поддерживает широкий спектр возможностей обогащения изображений с помощью класса `ImageDataGenerator`. Этот класс создает генератор для генерирования пакетов обогащенных (или аугментированных) изображений. Инициализатор класса принимает на входе ноль или более параметров для указания типа обогащения. Вот несколько параметров, которые мы рассмотрим в данном разделе:

- `horizontal_flip=True|False`;
- `vertical_flip=True|False`;
- `rotation_range=градусы`;
- `zoom_range=(нижний, верхний)` ;
- `width_shift_range=процент`;

- `height_shift_range=процент`;
- `brightness_range=(нижний, верхний)`.

ПЕРЕВОРОТ

В следующем ниже примере исходного кода делается следующее:

- 1 читается одно изображение яблока;
- 2 создается пакет из одного изображения (яблока);
- 3 инстанцируется класс `ImageDataGenerator`;
- 4 экземпляр класса `ImageDataGenerator` инициализируется опциями обогащения (в данном случае горизонтальным и вертикальным переворотами);
- 5 применяется метод `flow()` класса `ImageDataGenerator`, который создает генератор пакетов;
- 6 генератор повторяется шесть раз, всякий раз возвращая в `x` пакет, состоящий из одного изображения:
 - генератор будет случайно выбирать одно обогащение (включая отсутствие обогащения) в расчете на итерацию;
 - после преобразования (обогащения) пиксельные значения будут иметь 32-битный тип с плавающей точкой;
 - тип пиксельных данных меняется обратно на 8-битный целочисленный для вывода на экран с помощью библиотеки `Matplotlib`.

Вот исходный код:

```
from tensorflow.keras.preprocessing.image import ImageDataGenerator
import cv2
import numpy as np
from matplotlib import pyplot as plt

image = cv2.imread('apple.jpg')
batch = np.asarray([image])

datagen = ImageDataGenerator(horizontal_flip=True, vertical_flip=True)

step=0
for x in datagen.flow(batch, batch_size=1):
    step += 1
    if step > 6: break
    plt.figure()
    plt.imshow(x[0].astype(np.uint8))
```

Делает пакет из одного изображения (яблока)

Создает генератор для обогащения данных

Выполняет генератор, где каждое изображение представляет собой результат случайного обогащения

Операция обогащения изменяет тип пиксельных данных на float, а затем изменяет их обратно на uint8 для вывода изображения на экран

ПОВОРОТ

В следующей ниже строке кода используется параметр `rotation_range`, в котором случайные повороты устанавливаются в диапазоне от -60° до 60° . Обратите внимание, что операция поворота не выполняет проверку границ и изменение размера (например, используя `imutils.rotate_bound()`), поэтому часть изображения может быть обрезана:

```
datagen = ImageDataGenerator(rotation_range=60)
```

МАСШТАБИРОВАНИЕ

В данном исходном коде используется параметр `zoom_range`, в котором устанавливаются случайные значения от 0.5 (уменьшение масштаба) до 2 (увеличение масштаба). Значение может быть задано либо в виде кортежа, либо в виде списка из двух элементов:

```
datagen = ImageDataGenerator(zoom_range=(0.5, 2))
```

Сдвиг

В данном исходном коде используются параметры `width_shift_range` и `height_shift_range`, в которых устанавливается случайное значение от 0 до 20 % для сдвига по горизонтали либо по вертикали:

```
datagen = ImageDataGenerator(width_shift_range=0.2, height_shift_range=0.2)
```

Яркость

В следующей ниже строке исходного кода используется параметр `brightness_range`, в котором устанавливаются случайные значения от 0.5 (темнее) до 2 (ярче). Значение может быть задано либо в виде кортежа, либо в виде списка из двух элементов:

```
datagen = ImageDataGenerator(brightness_range=(0.5, 2))
```

В заключение отметим, что такие преобразования, как яркость, которые к значению пиксела добавляют фиксированную величину, выполняются после нормализации либо стандартизации. Если бы это было сделано до них, то нормализация и стандартизация привели бы значения в тот же самый изначальный диапазон, отменив преобразование.

4.9 Сырые (дисковые) наборы данных

Ранее мы обсуждали технические приемы тренировки, используя изображения, которые хранятся и доступны непосредственно из памяти. Это работает в случае малых наборов данных, например с крошечными изображениями, или в случае более крупных изображений в наборах данных, содержащих менее 50 000 изображений. Но как только мы начинаем выполнять тренировку с крупноразмерными изображениями и с большими числами изображений, такими как несколько сотен тысяч изображений, то ваш набор данных, скорее всего, будет храниться на диске. В этом подразделе рассматриваются общие традиционные подходы к хранению изображений на диске и доступа к ним для проведения тренировки.

Помимо курируемых наборов данных, используемых в академических/исследовательских целях, наборы данных, которые мы ис-

пользуем в производстве, скорее всего, хранятся на диске (или в базе данных, если данные структурированы). При работе с изображениями необходимо делать следующее:

- 1 читать изображения и соответствующие метки с диска в память (при условии что данные изображений помещаются в память);
- 2 изменять размер изображений в соответствии с входным вектором сверточной нейросети.

Далее мы охватим несколько распространенных методов, используемых для размещения наборов изображений на диске.

4.9.1 Каталожная структура

Размещение изображений в каталожной структуре папок на локальном диске является одной из наиболее распространенных компоновок. В этой компоновке, которая показана на рис. 4.19, корневая (родительская) папка является контейнером набора данных. Ниже корневого уровня находится один или несколько подкаталогов. Каждый подкаталог соответствует классу (метке) и содержит изображения, соответствующие этому классу.

Используя наш пример с кошками и собаками, у нас будет родительский каталог, который может называться `cats_n_dogs`, с двумя подкаталогами, один из которых называется `cats`, а другой – `dogs`. В каждом подкаталоге будет соответствующий класс изображений.




Рис. 4.19 Каталогная компоновка папок по классам

В качестве альтернативы, если набор данных ранее был разделен на тренировочные и тестовые данные, сначала мы группируем дан-

ные по тренировочным/тестовым, а затем группируем данные по двум классам, кошкам и собакам, как показано на рис. 4.20.

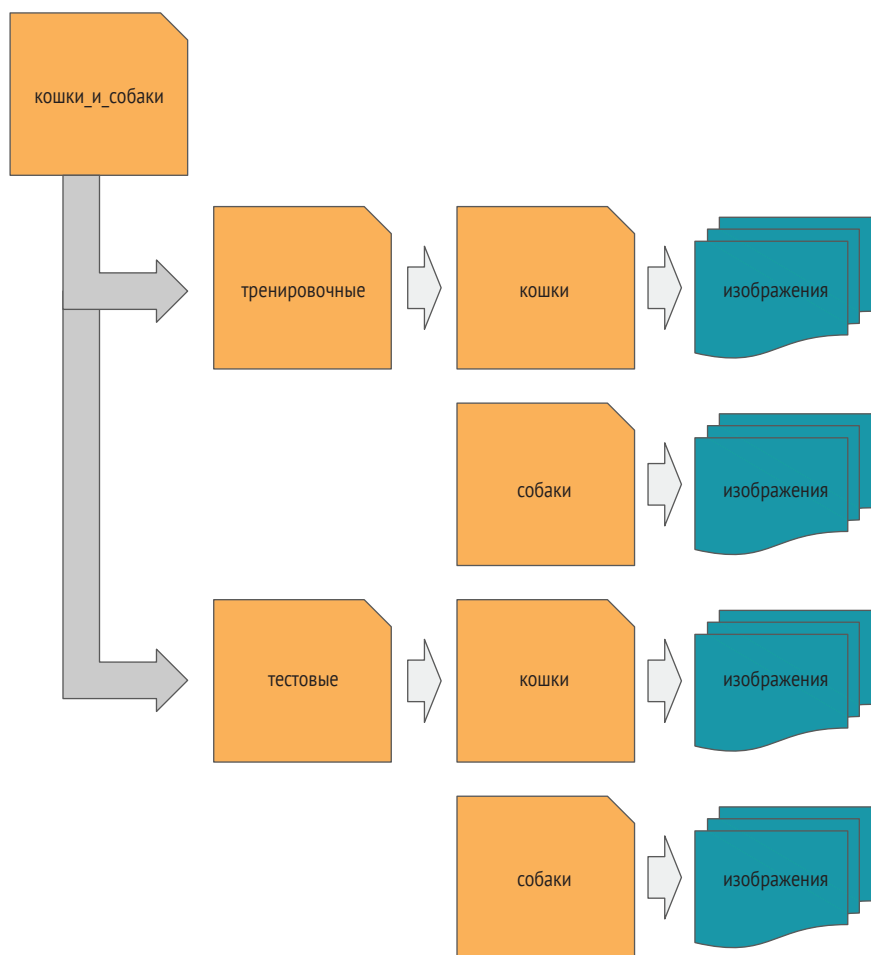


Рис. 4.20 Каталогная компоновка папок для разбивки на тренировочные и тестовые данные

Когда набор данных помечен иерархически, каждая подпапка верхнеуровневого класса (метки) подразделяется далее на дочерние подпапки в соответствии с иерархией классов (меток). Используя наш пример с кошками и собаками, каждое изображение помечено иерархически по виду, кошка либо собака, а затем по породе. См. рис. 4.21.

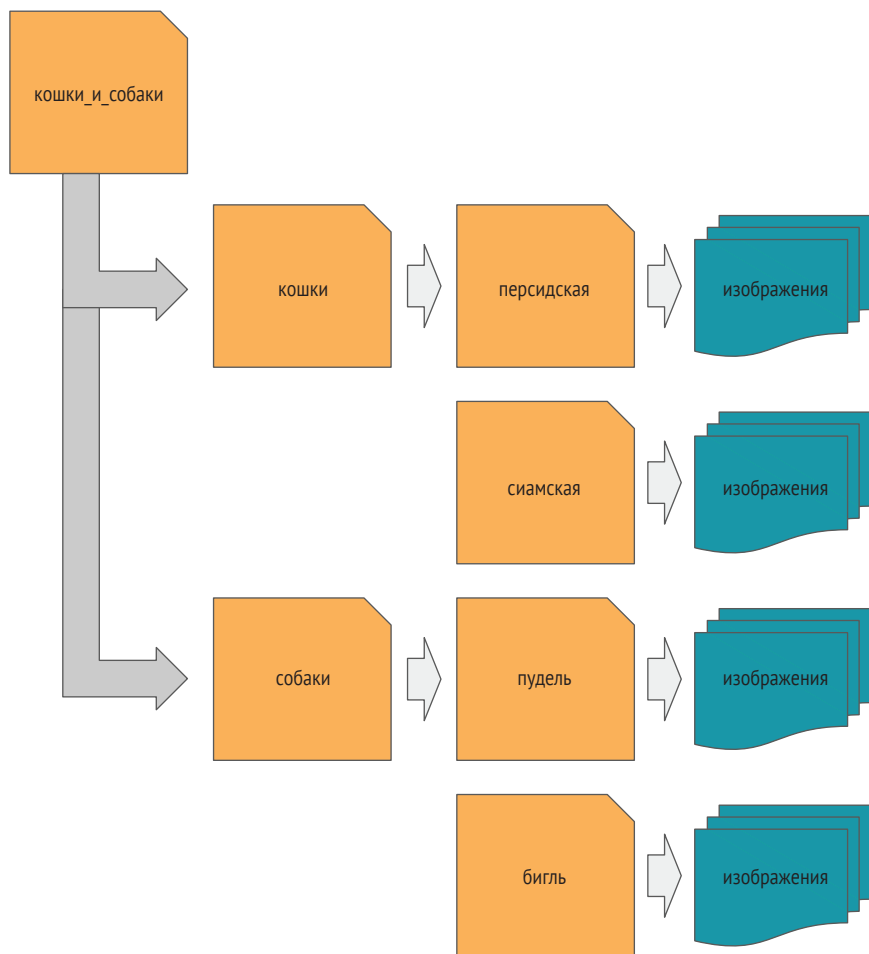


Рис. 4.21 Иерархическая каталожная компоновка папок для иерархической разметки

4.9.2 Файл CSV

Еще одной распространенной компоновкой является файл значений, разделенных запятыми (CSV), используемый для определения местоположения и класса (метки) каждого изображения. В этом случае каждая строка в файле CSV представляет собой отдельное изображение, и файл CSV содержит по меньшей мере два столбца, один для местоположения изображения, а другой для класса (метки) изображения. Местоположение может быть локальным путем, удаленным местоположением либо пиксельными данными, внедренными в качестве значения местоположения:

- пример локального пути:

```
label,location
'cat', cats_n_dogs/cat/1.jpg
'dog',cats_n_dogs/dog/2.jpg
...
```

- пример удаленного пути:

```
label,location
'cat','http://mysite.com/cats_n_dogs/cat/1.jpg'
'dog','http://mysite.com/cats_n_dogs/dog/2.jpg'
...
```

- пример внедренных данных:

```
label,location
'cat',[[...],[...],[...]]
'dog',[[...],[...],[...]]
...
```

4.9.3 Файл JSON

Еще одной распространенной компоновкой является файл нотации объектов JavaScript (JSON), используемый для определения местоположения и класса (метки) каждого изображения. В этом случае файл JSON является массивом объектов; каждый объект представляет собой отдельное изображение, и каждый объект имеет по меньшей мере два ключа, один для местоположения изображения, а другой для класса (метки) изображения.

Местоположение может быть либо локальным путем, либо удаленным местоположением, либо внедренными пиксельными данными в качестве значения местоположения. Вот пример локального пути:

```
[
    {'label': 'cat', 'location': 'cats_n_dogs/cat/1.jpg' },
    {'label': 'dog', 'location': 'cats_n_dogs/dog/2.jpg'}
    ...
]
```

4.9.4 Чтение изображений

При проведении тренировки на дисковом наборе данных первым шагом является чтение изображения с диска в память. Изображение хранится на диске в формате изображения, таком как JPG, PNG или TIF. Эти форматы определяют тип кодирования и сжатия изображения для целей хранения. Изображение может быть прочитано в память с помощью метода `Image.open()` библиотеки PIL:

```
from PIL import Image
image = Image.open('myimage.jpg')
```

На практике вам будет требоваться читать в память большое число изображений. Предположим, вы хотите прочитать все изображения в указанном подкаталоге (например, cats). В следующем ниже фрагменте исходного кода мы сканируем (перечисляем) все файлы в подкаталоге, читаем каждый из них как изображение и сохраняем список прочитанных изображений в виде списка:

```
from PIL import Image
import os

def loadImages(subdir):
    images = []
    files = os.scandir(subdir)
    for file in files:
        images.append(Image.open(file.path))
    return images

loadImages('cats')
```

Процедура чтения всех изображений в подпапке для одной классовой метки

Получает список всех файлов из подкаталога cats

Читает все изображения в подпапке cats

Читает каждое изображение в память и добавляет это изображение в конец списка

Обратите внимание, что в Python 3.5 была добавлена функция `os.scandir()`. Если вы используете Python 2.7 или более раннюю версию Python 3, то ее совместимую версию можно получить с помощью команды `pip install scandir`.

Давайте остановимся на предыдущем примере подробнее и допустим, что набор изображений представлен в виде каталожной структуры; каждый подкаталог представляет класс (метку). В этом случае мы хотели бы сканировать каждый подкаталог по отдельности и вести для классов запись имен подкаталогов:

```
import os

def loadDirectory(parent):
    classes = {}
    dataset = []
    for subdir in os.scandir(parent):
        if not subdir.is_dir():
            continue
        classes[subdir.name] = len(dataset)
        dataset.append(loadImages(subdir.path))
    print("Обработан подкаталог:", subdir.name, "Число изображений",
          len(dataset[len(dataset)-1]))
    return dataset, classes

loadDirectory('cats_n_dogs')
```

Поддерживает соотнесенность класса (именем подкаталога) с меткой (индексом)

Процедура чтения всех изображений набора данных по классу

Получает список всех подкаталогов под родительским (корневым) каталогом набора данных

Игнорирует любую запись, которая не является подкаталогом (например, файл лицензии)

Возвращает пары изображение-класс набора данных

Читает все изображения по классу для набора данных cats_n_dogs

Теперь давайте попробуем пример, в котором местоположение изображения является удаленным (т. е. нелокальным) и задано URL-адресом. В этом случае нам нужно сделать HTTP-запрос содержимого ресурса (изображения), указанного в URL-адресе, а затем декодировать ответ в двоичный байтовый поток:

```
from PIL import Image
import requests
from io import BytesIO

def remoteImage(url):
    try:
        response = requests.get(url)
        return Image.open(BytesIO(response.content))
    except:
        return None
```

← Пакет Python для HTTP-запросов

← Пакет Python для десериализации ввода-вывода в байтовый поток

Запрашивает содержимое изображения по указанному URL-адресу →

Читает десериализованное содержимое в память как изображение ←

После того как вы прочитали изображения для тренировки, необходимо задать число каналов, соответствующее входной форме вашей сверточной нейронной сети, например один канал для полутоновых изображений или три канала для изображений RGB.

Число каналов – это число цветовых плоскостей в вашем изображении. Например, полутоновое изображение будет иметь один цветовой канал. Цветное изображение RGB будет иметь три цветовых канала, по одному для красного, зеленого и синего. В большинстве случаев это будет либо один канал (оттенки серого), либо три канала (RGB), как показано на рис. 4.22.

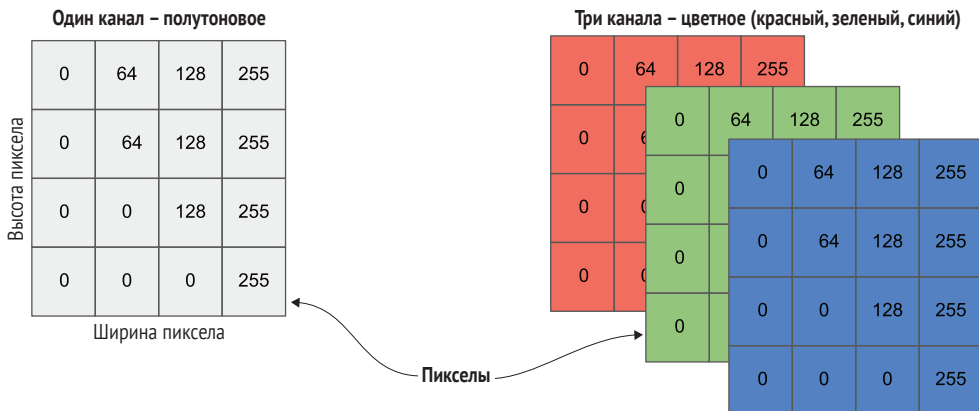


Рис. 4.22 Полутоновое изображение имеет один канал, а изображение RGB – три канала

Метод `Image.open()` будет читать изображение в соответствии с числом каналов в изображении, хранящемся на диске. Поэтому если оно является полутоновым, то указанный метод будет читать его как один канал; если же это RGB, то он будет читать его как три

канала; и если это RGBA (плюс альфа-канал), то он будет читать его как четыре канала.

В общем случае во время работы с изображениями RGBA альфа-канал может быть удален. Это просто маска для настройки прозрачности каждого пиксела изображения, и поэтому он не содержит информации, которая иначе способствовала бы распознаванию изображения.

После того как изображение будет прочитано в память, следующим шагом будет конвертирование изображения в число каналов, соответствующих входной форме вашей нейронной сети. Поэтому если нейронная сеть принимает полутоновые изображения (один канал), то мы хотим конвертировать их в оттенки серого; или если нейронная сеть принимает изображения RGB (три канала), то мы хотим конвертировать в RGB. Метод `convert()` выполняет канальную конверсию. Значение `L` параметра конвертирует в один канал (оттенки серого), а значение `RGB` конвертирует в три канала (цвет RGB). Ниже мы обновили функцию `LoadImages()`, чтобы включить канальную конверсию:

```
from PIL import Image
import os

def loadImages(subdir, channels):
    images = []
    files = os.scandir(subdir)

    for file in files:
        image = Image.open(file.path)
        if channels == 1:
            image = image.convert('L')
        else:
            image = image.convert('RGB')
        images.append(image)
    return images

loadImages('cats', 3)  ← Задает конверсию в RGB
```

4.9.5 Изменение размера

До этого места в книге мы познакомились с тем, как читать изображение с диска, получать метку, а затем устанавливать число каналов, соответствующее числу каналов во входной форме сверточной нейросети. Далее нам нужно изменить размер высоты и ширины изображения, чтобы завершить согласование входной формы для подачи изображений во время тренировки.

Например, 2-мерная сверточная нейронная сеть будет принимать следующую форму: (высота, ширина, каналы). Мы уже разобрались в части, касающейся канала, поэтому теперь нам нужно изменить пиксельную высоту и ширину каждого изображения, чтобы они соответ-

ствовали входной форме. Например, если входная форма составляет (128, 128, 3), то мы хотим изменить высоту и ширину каждого изображения на (128, 128). Метод `resize()` выполнит изменение размера.

В большинстве случаев вы будете уменьшать размер (отбирать с пониженной частотой из) каждого изображения. Например, изображение размером 1024×768 будет иметь размер 3 Мб. Это гораздо более высокая разрешающая способность, чем требуется для работы нейронной сети (подробнее об этом см. в главе 3). При уменьшении размера изображения некоторые параметры (детали) будут потеряны. В целях минимизирования эффекта при уменьшении размера в библиотеке PIL обычно используется алгоритм подавления артефактов¹. Наконец, мы захотим конвертировать наш список изображений PIL в многомерный массив:

```
from PIL import Image
import os
import numpy as np

def loadImages(subdir, channels, shape):
    images = []

    files = os.scandir(subdir)
    for file in files:
        image = Image.open(file.path)
        if channels == 1:
            image = image.convert('L')
        else:
            image = image.convert('RGB')
        images.append(image.resize(shape, Image.ANTIALIAS))

    return np.asarray(images)
```

Конвертирует все изображения PIL в массивы NumPy одним вызовом

Изменяет размер изображения на целевую входную форму

Указывает целевой входной размер 128×128

Теперь давайте повторим предыдущие шаги с помощью библиотеки OpenCV. Изображение читается в память с помощью метода `cv2.imread()`. Одним из первейших преимуществ, которые я нахожу в этом методе, является то, что на выходе из него уже имеется многомерный тип данных NumPy:

```
import cv2

image = cv2.imread('myimage.jpg')
```

Еще одно преимущество библиотеки OpenCV перед библиотекой PIL заключается в том, что в ней можно выполнять канальную

¹ Алиасинг (aliasing), дословно «псевдонимизация», – это эффект, когда разные сигналы становятся неразличимыми, т. е. когда они становятся псевдонимами друг друга. Отсюда и название процедуры устранения артефактов в английском языке – anti-aliasing (антипсевдонимизация). – Прим. перев.

конверсию во время чтения изображения в память вместо второго шага. По умолчанию `cv2.imread()` конвертирует изображение в трехканальное изображение RGB. Вы можете указать второй параметр, который задает требуемый вид канальной конверсии. В следующем ниже примере мы выполняем канальную конверсию во время чтения изображения в память:

Читает изображение в память как
одноканальное (полутоновое) изображение

```
→ if channel == 1:
    image = cv2.imread('myimage.jpg', cv2.IMREAD_GRAYSCALE)
→ else:
    image = cv2.imread('myimage.jpg', cv2.IMREAD_COLOR)
```

Читает изображение в память
как трехканальное (цветное) изображение

В следующем ниже примере мы читаем изображение в память из удаленного местоположения (URL-адреса) и одновременно выполняем канальную конверсию. В данном случае мы используем метод `cv2.imdecode()`:

```
try:
    response = requests.get(url)
    if channel == 1:
        return cv2.imdecode(BytesIO(response.content),
                               cv2.IMREAD_GRAYSCALE)
    else:
        return cv2.imdecode(BytesIO(response.content),
                               cv2.IMREAD_COLOR)
except:
    return None
```

Размеры изображений изменяются с помощью метода `cv2.resize()`. Второй параметр – это кортеж высоты и ширины изображения с измененным размером. Необязательный третий (именованный) параметр – это алгоритм интерполяции, используемый при изменении размера. Поскольку в большинстве случаев вы будете использовать отбор с пониженной частотой, традиционной практикой является применение алгоритма `cv2.INTER_AREA`. Это делается для достижения наилучших результатов в сохранении информации и минимизировании артефактов при отборе из изображения с пониженной частотой:

```
image = cv2.resize(image, (128, 128), interpolation=cv2.INTER_AREA)
```

Теперь давайте перепишем функцию `LoadImages()` с помощью библиотеки OpenCV:

```
import cv2
import os
import numpy as np
```

```
def loadImages(subdir, channels, shape):
    images = []
```

```
    files = os.scandir(subdir)
    for file in files:
```

Изменяет размер
изображения
на целевую
входную форму

```
        if channels == 1:
            image = cv2.imread(file.path, cv2.IMREAD_GRAYSCALE)
        else:
            image = cv2.imread(file.path, cv2.IMREAD_COLOR)
```

```
    images.append(cv2.resize(image, shape, cv2.INTER_AREA))
    return np.asarray(images)
```

```
loadImages('cats', 3, (128, 128)) ← Задаёт целевую входную форму как 128×128
```

4.10 Сохранение/восстановление модели

В этом подразделе мы рассмотрим посттренировку: что делать дальше теперь, когда вы натренировали модель? Ну, вы, пожалуй, захотите сохранить модельную архитектуру и соответствующие усвоенные веса и смещения (параметры), а затем впоследствии восстановить модель для развертывания.

4.10.1 Сохранение

В TF.Keras можно сохранять как модель, так и усвоенные параметры (веса и смещения). Модель и веса могут быть сохранены отдельно либо вместе. Метод `save()` сохраняет как веса/смещения, так и модель в указанную папку в формате сохраненной модели SavedModel каркаса TensorFlow. Вот пример:

Тренирует
модель

```
model.fit(x_train, y_train, epochs=epochs, batch_size=batch_size)
```

```
model.save('mymodel') ← Сохраняет модель и усвоенные веса и смещения
```

Усвоенные веса/смещения и модель могут быть сохранены отдельно. Метод `save_weights()` сохраняет в указанную папку только модельные параметры в формате контрольной точки TensorFlow. Вот пример:

```
model.fit(x_train, y_train, epochs=epochs, batch_size=batch_size)
```

```
model.save_weights('myweights') ← Сохраняет только усвоенные веса и смещения
```

4.10.2 Восстановление

В TF.Keras можно восстанавливать модельную архитектуру и/или модельные параметры (веса и смещения). Восстановление модельной архитектуры обычно выполняется для загрузки предварительно по-

строенной модели, а загрузка как модельной архитектуры, так и модельных параметров обычно выполняется для переноса обучения (обсуждается в главе 11).

Обратите внимание, что загрузка модели и модельных параметров – это не то же самое, что и фиксация контрольной точки, поскольку мы не восстанавливаем текущее состояние гиперпараметров. Поэтому указанный подход не следует использовать для непрерывного усвоения:

```
from tensorflow.keras.models import load_model

model = load_model('mymodel') ← Загружает преднатренированную модель
```

В следующем ниже примере исходного кода натренированные веса/смещения модели загружаются в соответствующую предварительно построенную модель с помощью метода `load_weights()`:

```
from tensorflow.keras.models import load_weights

model = load_model('mymodel') ← Загружает предварительно построенную модель
model.load_weights('myweights') ← Загружает преднатренированные веса модели
```

Резюме

- Когда пакет изображений подается через сеть в прямом направлении, разница между предсказанным значением и фундаментальными истинами равна потере. Потеря используется оптимизатором для определения способа обновления весов при обратном распространении.
- Небольшой объем набора данных откладывается в сторону в качестве тестовых данных и в тренировке не участвует. После тренировки тестовые данные используются для наблюдения за тем, насколько хорошо модель обобщает по сравнению с запоминанием примеров данных.
- Валидационные данные используются после каждой эпохи для обнаружения переобучения модели.
- Стандартизация пиксельных данных предпочтительнее нормализации, поскольку она способствует несколько более высокой скорости схождения.
- Схождение наступает во время тренировки, когда потеря выходит на плато.
- Гиперпараметры используются для улучшения тренировки модели, но не являются частью модели.
- Обогащение позволяет выполнять тренировку под инвариантность с меньшим числом изначальных изображений.
- Фиксация контрольной точки используется для восстановления хорошей эпохи без перезапуска тренировки, после того как тренировка разошлась.

- Ранняя остановка экономит время и расходы на тренировку за счет выявления ситуаций, когда дальнейшая тренировка не приведет к улучшению модели.
- Малые наборы данных могут подаваться для проведения тренировки из хранилища, расположенного в памяти, но крупные наборы данных подаются из хранилища, расположенного на диске.
- После тренировки модельная архитектура и усвоенные параметры сохраняются, и впоследствии модель восстанавливается для развертывания.

Часть II

Базовый шаблон конструирования

Во второй части вы узнаете, как конструировать и кодировать модели с использованием шаблона конструирования «Процедурное реиспользование». Я покажу вам, как просто и легко применять процедурное реиспользование, являющееся основополагающим принципом в разработке программно-информационного обеспечения, к моделям глубокого обучения. Вы увидите, как раскладывать модель на три стандартных компонента – стержень, ученика и задачу – вместе с коммуникационным интерфейсом между компонентами и как применять шаблон процедурного реиспользования для кодирования каждой части.

Далее вы узнаете, как применять этот шаблон конструирования к различным эпохальным передовым моделям компьютерного зрения, а также к нескольким примерам из структурированных данных и обработки естественного языка (NLP). Я проведу вас по кодированию последовательности передовых моделей и расскажу об их вкладе в развитие глубокого обучения: VGG, ResNet, ResNeXt, Inception, DenseNet, WRN, Xception и SE-Net. Затем мы обратимся к мобильным моделям для устройств с ограниченной памятью, таких как мобильные телефоны или датчики интернета вещей. Мы рассмотрим развитие конструктивных принципов, которые были разработаны для придания моделям возможности работать на устройствах с ограниченным объемом памяти, начиная с MobileNet, затем SqueezeNet и ShuffleNet. Опять же, каждую из этих мобильных моделей мы будем кодировать с помощью шаблона конструирования «Процедурное ре-

использование», а затем вы узнаете, как развертывать и обслуживать эти модели с помощью каркаса TensorFlow Lite.

Большинство глав части II посвящены моделям для контролируемого усвоения, в котором данные помечены. Но в последней главе представлены автокодировщики, выполняющие неконтролируемое усвоение во время тренировки модели с помощью данных, которые не были помечены человеком. Вы научитесь конструировать и кодировать автокодировщики для сжатия, устранения шума на изображениях, придания сверхразрешающей способности и других задач.

Шаблон процедурного конструирования

Эта глава охватывает следующие ниже темы:

- знакомство с шаблоном процедурного конструирования для сверточной нейронной сети;
- разложение архитектуры процедурного шаблона конструирования на макро- и микрокомпоненты;
- кодирование некогда передовых моделей с использованием шаблона процедурного конструирования.

До 2017 года большинство имплементаций нейросетевых моделей кодировались в стиле пакетных сценариев. По мере того как исследователи ИИ и опытные инженеры-программисты все активнее вовлекались в исследования и конструирование, мы начали замечать изменения в кодировании моделей, отражающие принципы разработки программно-информационного обеспечения, связанные с реиспользованием и шаблонами конструирования.

В самых ранних версиях использования шаблонов конструирования, предназначенных для нейросетевых моделей, применялся процедурный стиль реиспользования. Из шаблона конструирования следует, что ныне существует лучший образец практики строительства и кодирования модели, который может применяться многократно в широком спектре случаев, таких как классифицирование изображений, обнаружение и отслеживание объектов, распознавание лиц, сегментирование изображений, наделение изображений сверхразрешающей способностью и перенос стиля.

Итак, каким образом внедрение шаблонов конструирования помогло в продвижении сверточных нейросетей (а также других архи-

текстур, таких как трансформеры в обработке естественного языка)? Во-первых, это помогло другим исследователям понимать и воспроизводить модельную архитектуру. Разложение модели на ее реиспользуемые компоненты или шаблоны предоставило другим практикам возможность наблюдать, понимать, а затем проводить эффективные эксперименты на устройствах.

Мы видим, что это происходит уже при переходе с AlexNet на VGG. Авторам AlexNet (<http://mng.bz/1ApV>) не хватало ресурсов для работы модели AlexNet на одном GPU. Они разработали сверточную нейросетевую архитектуру для работы в параллельном режиме на двух GPU. В целях решения этой задачи им пришла в голову идея конструкции с двумя зеркальными путями свертки, конструкция, которая выиграла конкурс ILSVRC 2012 года на классифицирование изображений. Вскоре другие исследователи ухватились за идею создания сверточного шаблона, который можно повторять, и начали изучать эффекты сверточного шаблона в дополнение к анализу совокупной производительности. В 2014 году обе исследовательские группы GoogLeNet (<https://arxiv.org/abs/1409.4842>) и VGG (<https://arxiv.org/pdf/1409.1556.pdf>) основывали свои модели и соответствующие исследовательские работы на использовании повторяющегося сверточного шаблона; эти инновации заняли соответственно первое и второе места в конкурсе ILSVRC 2014 года.

Понимание архитектуры шаблона процедурного конструирования играет важнейшую роль, если вы собираетесь применять его к любой создаваемой модели. В этой главе я сначала покажу то, как этот шаблон строится, разложив его на макроархитектурные компоненты, а затем на микроархитектурные группы и блоки. Увидев работу деталей по отдельности и вместе, вы будете готовы приступить к работе с исходным кодом, который строит эти детали.

В целях демонстрации того, как шаблон процедурного конструирования облегчает воспроизведение модельных компонентов, мы затем применим его к нескольким некогда передовым моделям: VGG, ResNet, ResNeXt, Inception, DenseNet и SqueezeNet. Эта практика должна дать вам более глубокое понимание принципа работы данных моделей и практический опыт их воспроизведения. Некоторые примечательные особенности этих архитектур заключаются в следующем:

- VGG – победитель 2014 года в классифицировании изображений в конкурсе ImageNet ILSVRC;
- ResNet – победитель 2015 года в классифицировании изображений в конкурсе ImageNet ILSVRC;
- ResNeXt – 2016, авторы повышают точность за счет введения широкого сверточного слоя;
- Inception – победитель конкурса 2014 года в обнаружении объектов в конкурсе ImageNet ILSVRC;
- DenseNet – 2017, авторы представили реиспользование карт признаков;

- SqueezeNet – 2016, авторы вводят концепцию конфигурируемого компонента.

Мы кратко рассмотрим один шаблон процедурного конструирования, основанный на шаблоне идиоматического конструирования для сверточных нейросетевых моделей.

5.1 Базовая нейросетевая архитектура

Шаблон идиоматического конструирования трактует модель как состоящую из шаблона совокупной макроархитектуры, а затем каждый макрокомпонент, в свою очередь, состоит из микроархитектурной конструкции. Концепция макро- и микроархитектуры для модели была представлена в исследовательской работе по архитектуре SqueezeNet в 2016 году (<https://arxiv.org/abs/1602.07360>). Для сверточной нейросети макроархитектура подчиняется традиции, предусматривающей наличие трех макрокомпонентов: стержня (stem), ученика (learner) и задачи (task), как показано на рис. 5.1.

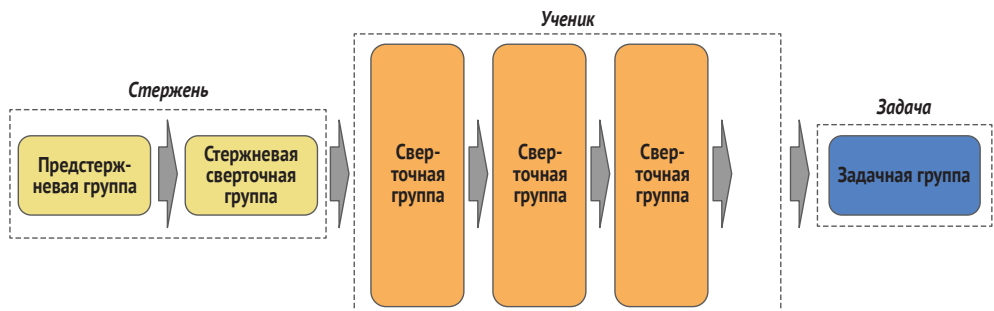


Рис. 5.1 Сверточная нейросетевая макроархитектура состоит из трех компонентов: стержня, ученика и задачи

Как вы могли заметить, *стержневой* компонент принимает входные данные (изображение) и выполняет начальное выделение признаков грубого уровня, которые становятся входными данными для ученического компонента. В этом примере стержень включает в себя предстержневую группу, которая выполняет предобработку данных, и стержневую сверточную группу, которая выполняет выделение признаков грубого уровня.

Ученик, который может состоять из любого числа сверточных групп, затем выполняет детальное выделение признаков и усвоение представления из грубых признаков. Результат работы ученического компонента называется *латентным пространством*.

Задачный компонент усваивает задачу (например, классифицирование) из представления входных данных в латентном пространстве.

Хотя в этой книге основное внимание уделяется сверточным нейросетям, указанная макроархитектура компонентов «стержень», «ученик» и «задача» может применяться к другим нейросетевым архитектурам, таким как трансформерные сети с механизмами внимания в обработке естественного языка.

Глядя на скелетную заготовку шаблона идиоматического конструирования с использованием функционального API, вы можете увидеть поток данных между компонентами на высоком уровне. Мы будем использовать эту заготовку (в следующем ниже блоке исходного кода) и опираться на него во всех главах, в которых используется шаблон идиоматического конструирования. Скелет состоит из двух главных компонентов:

- функциональных (процедурных) определений главенствующих компонентов: стержня, ученика и задачи;
- входных (тензорных) потоков через главенствующие компоненты.

Ниже приведена скелетная заготовка:

```
def stem(input_shape):  ←———— Строит стержневой компонент
    ''' слой стержня
        input_shape : форма входного тензора
    ...
    return outputs

def learner(inputs):  ←———— Строит ученический компонент
    ''' слой ученика
        inputs : входные тензоры (карты признаков)
    ...
    return outputs

def task(inputs, n_classes):  ←———— Строит задачный компонент для классификатора
    ''' слой классификатора
        inputs : входные тензоры (карты признаков)
        n_classes : число выходных классов
    ...
    return outputs

inputs = Input(input_shape=(224, 224, 3))  ←———— Определяет входной тензор
outputs = stem(inputs)
outputs = learner(outputs)
outputs = task(x, n_classes=1000)
model = Model(inputs, outputs)  ←———— Собирает модель
```

В этом примере библиотечный класс `Input` определяет входной тензор модели; в случае сверточной нейросети он состоит из формы изображения. Кортеж `(224, 224, 3)` относится к (трехканальному) изображению `224×224 RGB`. Библиотечный класс `Model` является заключительным шагом при кодировании нейронной сети с использованием функционального API `TF.Keras`. Этот шаг является заключительным шагом сборки (именуемым методом `compile()`) модели.

Параметрами класса `Model` являются модельный входной тензор(ы) и выходной тензор(ы). В нашем примере у нас один входной и один выходной тензоры. Эти шаги показаны на рис. 5.2.

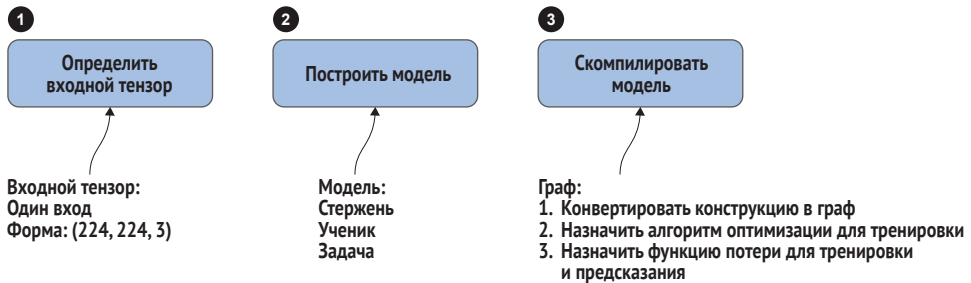


Рис. 5.2 Шаги строительства сверточной нейросетевой модели: определение входных данных, строительство компонентов, компиляция в виде графа

Теперь давайте рассмотрим эти три макрокомпонента подробнее.

5.2 Стержневой компонент

Стержневой компонент является точкой входа в нейронную сеть. Его первостепенная цель состоит в том, чтобы выполнить первое (грубое) выделение признаков, при этом сокращая карты признаков до размера, предназначенного для учебного компонента. Число карт признаков и размеры карты признаков, выдаваемые стержневым компонентом, определяются за счет одновременного балансирования двух критериев:

- максимизировать выделение признаков грубого уровня. Здесь цель состоит в том, чтобы предоставить модели достаточно информации для усвоения признаков более детализированного уровня в пределах способности модели;
- минимизировать число параметров в нижестоящем учебном компоненте. В идеале вы хотите минимизировать размер карт признаков и время, необходимое на тренировку модели, но без ущерба для производительности модели.

Эта начальная задача выполняется *стержневой сверточной группой*. Теперь давайте рассмотрим несколько вариаций стержневых групп из ограниченного ряда хорошо известных сверточных нейросетевых моделей: VGG, ResNet, ResNeXt и Inception.

5.2.1 VGG

Архитектура VGG, победитель конкурса ImageNet ILSVRC 2014 года в классифицировании изображений, считается отцом современных сверточных нейросетей, тогда как архитектура AlexNet считается де-

душкой. Архитектура VGG формализовала концепцию строительства сверточной нейросети из компонентов и групп с помощью шаблона. До VGG сверточные нейросети строились как сети ConvNet, полезность которых не выходила за рамки академических новинок.

Сети VGG были первыми, которые получили практическое применение в производстве. В течение нескольких лет после разработки указанной архитектуры исследователи продолжали сравнивать более современные передовые архитектурные разработки с VGG и использовать сети VGG для классификационной магистрали ранних новейших моделей обнаружения объектов.

В архитектуре VGG, наряду с Inception, формализована концепция наличия первой сверточной группы, выполнявшей выделение признаков грубого уровня, которые мы теперь называем *стержневым компонентом*. Последующие сверточные группы затем выполняли более детализированные уровни выделения и усвоения признаков, которые мы теперь называем *усвоением представления*, и отсюда термин «ученик» для этого второго главенствующего компонента.

В конечном итоге исследователи обнаружили недостаток стержня VGG: он удерживал размер входных данных (224×224) в выделенных картах грубых признаков, что приводило к излишнему числу параметров, поступавших на вход ученического компонента. Число параметров увеличивало объем памяти и снижало производительность тренировки и предсказания. Впоследствии эта проблема была исследователями решена в более поздних передовых моделях путем добавления сведения в стержневой компонент, сократив размер карт признаков грубого уровня. Это изменение сократило отпечаток памяти и одновременно повысило производительность без потери точности.

Традиционное правило выдавать 64 карты признаков грубого уровня сохраняется и сегодня, хотя некоторые современные сверточные нейросети могут выдавать 32 карты признаков.

Стержневой компонент архитектуры VGG, изображенный на рис. 5.3, был разработан для приема на входе изображений размером $224 \times 224 \times 3$ и выдачи 64 карт признаков, каждой размером 224×224 . Другими словами, стержневая группа VGG не сокращала размеры карт признаков.

Теперь взгляните на образец исходного кода для кодирования стержневого компонента архитектуры VGG в шаблоне идиоматического конструирования, который состоит из одного сверточного слоя (Conv2D). Указанный слой использует фильтр 3×3 для выделения признаков грубого уровня для 64 фильтров. Это не приводит к сокращению размера карт признаков. При вводе изображения формой $(224, 224, 3)$ (набор данных ImageNet) на выходе из этой стержневой группы будет форма $(224, 224, 64)$:

```
def stem(inputs):  
    """ Построить стержневую сверточную группу
```

```

inputs : входной тензор
"""
outputs = Conv2D(64, (3, 3), strides=(1, 1), padding="same",
                  activation="relu")(inputs)
return outputs

```

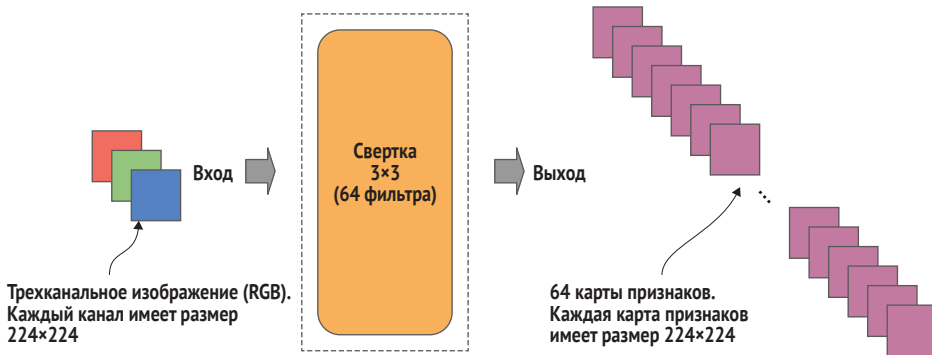


Рис. 5.3 Стержневая группа архитектуры VGG использует фильтр 3×3 для выделения признаков грубого уровня

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для VGG находится в репозитории на GitHub (<http://mng.bz/qe4w>).

5.2.2 ResNet

Архитектура ResNet (остаточно-сетевая), победитель конкурса ImageNet ILSVRC 2015 года в классифицировании изображений, была одной из первых, которая включала в себя традиционные шаги максимизирования выделения признаков грубого уровня и минимизирования параметров вместе с сокращением карт признаков. Сравнивая свою модель с VGG, авторы ResNet обнаружили, что они могут сокращать размер карт выделенных признаков на целых 94 % в стержневом компоненте, сокращая отпечаток памяти и повышая производительность модели, не влияя на ее точность.

ПРИМЕЧАНИЕ Процесс сравнения более новой модели с предыдущей передовой (SOTA) моделью называется абляционным исследованием и является обычной практикой в области машинного обучения. По сути, исследователи повторяют исследование предыдущей модели, а затем используют ту же конфигурацию (скажем, обогащение изображения или скорость усвоения) в своей новой модели. Это позволяет им проводить прямые сравнения сопоставимых величин с более ранними моделями.

Авторы архитектуры ResNet также решили использовать чрезвычайно крупный грубый фильтр размером 7×7 , который охватывал площадь в 49 пикселей. Их рассуждения при этом заключались в том, что для эффективности модели требовался очень крупный фильтр. Его недостатком было существенное увеличение операций матричного умножения, или `matmul`, в стержневом компоненте. В конце концов, исследователи впоследствии обнаружили, что в более поздних передовых моделях фильтр 5×5 был столь же эффективен и даже эффективнее. В традиционных сверточных нейросетях фильтр 5×5 обычно заменяется стопкой из двух фильтров 3×3 , при этом первая свертка не является пошаговой (без сведения), а вторая свертка является пошаговой (со сведением признаков).

В течение нескольких лет ResNet версии v1 и ее уточненная версия v2 стали фактической архитектурой, используемой в производстве для классифицирования изображений, и магистралью в моделях обнаружения объектов. Помимо улучшенной производительности и точности, стали широко распространены публичные версии преднатренированных сетей ResNet для задач классифицирования изображений, обнаружения объектов и сегментирования изображений, поэтому указанная архитектура также стала стандартом для переноса обучения. Даже сегодня, в высококласных модельных зоопарках, таких как TensorFlow Hub, преднатренированная ResNet v2 по-прежнему широко распространена для классифицирования изображений в качестве магистрали. Однако сегодня более современная традиция для предварительного классифицирования изображений состоит в применении меньшей, более быстрой и точной эффективной сети. На рис. 5.4 показаны слои в стержневом компоненте сети ResNet.

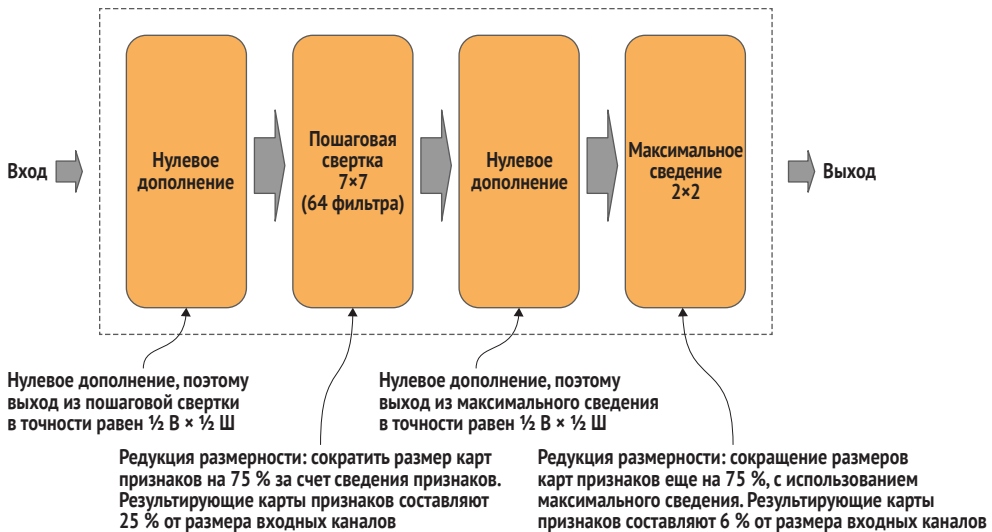


Рис. 5.4 Стержневой компонент остаточной сети (ResNet) агрессивно сокращает размеры карты признаков с помощью пошаговой свертки (т. е. с пошаговым сдвигом) и максимального сведения

Стержневой компонент в ResNet состоит из одного сверточного слоя для выделения грубых признаков. Для получения грубых признаков в модели используется размер фильтра 7×7 над более широким окном, в соответствии с теорией, что он будет извлекать более крупные признаки. Фильтр 7×7 охватывает 49 пикселей (в отличие от фильтра 3×3 , который охватывает 9 пикселей). Использование фильтра значительно более крупного размера также существенно увеличивает объем вычислений (матричных умножений) в расчете на фильтрный шаг (при скольжении фильтра по изображению). Матрица 3×3 имеет 9 матричных умножений на попиксельной основе, а матрица 7×7 имеет их 49. После архитектуры ResNet традиционная практика использовать 7×7 , чтобы получать более крупные признаки грубого уровня, больше не рассматривалась.

Обратите внимание, что стержневые компоненты обеих сетевых архитектур (VGG и ResNet) выводят 64 начальные карты признаков. Это распространенное традиционное правило, усвоенное исследователями методом проб и ошибок, по-прежнему широко применяется.

Для сокращения карт признаков стержневая группа сети ResNet выполняет и шаг сведения признаков (пошаговая свертка), и отбор с пониженной частотой (максимальное сведение).

В сверточном слое дополнение при перемещении фильтра по изображению не используется. И значит, когда фильтр достигает края изображения, он останавливается. Поскольку последние пиксели перед краем не получают от фильтра своего собственного шага скольжения, выходной размер меньше входного размера, как показано на рис. 5.5. Следствием этого является то, что размер входных и выходных карт признаков не сберегается. Например, в свертке с шагом 1, размером фильтра 3×3 и размером карты входных признаков 32×32 выходные карты признаков будут иметь размер 30×30 . Рассчитать по-

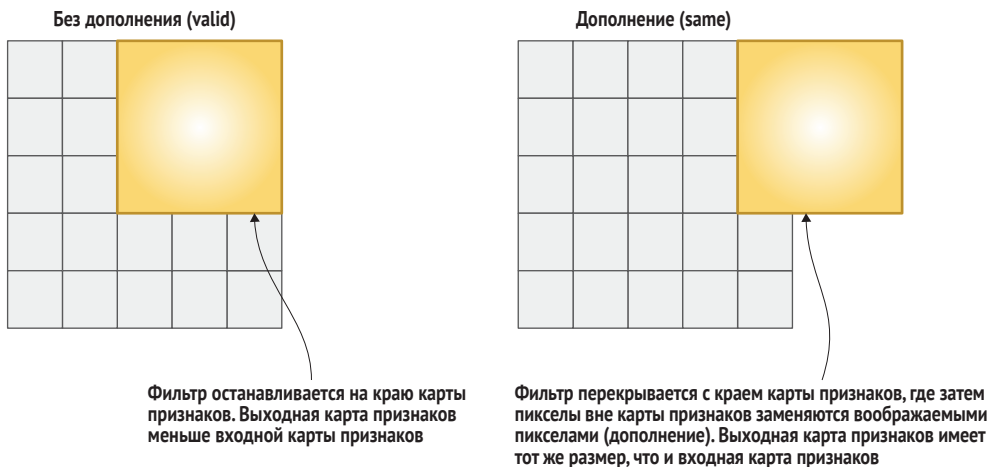


Рис. 5.5 Варианты с дополнением и без заполнения приводят к разным местам остановки фильтра

терю по размеру несложно. Если размер фильтра равен $N \times N$, то потеря в размере составит $N - 1$ пикселей. В TF.Keras это задается с помощью именного параметра `padding='valid'` для слоя `Conv2D`.

В качестве альтернативы можно сдвигать фильтр по краю до тех пор, пока не будут закрыты последняя строка и столбец. Но часть фильтра будет нависать над воображаемыми пикселями. Благодаря этому последние пиксели перед краем будут получать от фильтра свой собственный шаг скольжения, и размер выходной карты признаков сберегается.

Для дополнения воображаемых пикселей есть несколько стратегий. Наиболее распространенной и традиционной на сегодняшний день является дополнение воображаемых пикселей одинаковым пиксельным значением по краю, как показано на рис. 5.5. В TF.Keras это задается с помощью именованного параметра `padding='same'` для слоя `Conv2D`.

Архитектура ResNet предшествовала этой традиции и дополняла воображаемые пиксели нулевыми значениями; вот почему в стержневой группе вы видите слои `ZeroPadding2D`, где дополнение нулями размещено вокруг изображения. Сегодня мы обычно дополняем изображение тем же дополнением и откладываем сокращение размера карт признаков до собственно сведения и сведения признаков. Методом проб и ошибок исследователи выяснили, что этот подход дает наилучший результат в сбережении информации о выделении признаков на краю изображения.

На рис. 5.6 показана свертка с дополнением на изображении размером $H \times W \times 3$ (три канала для RGB). С помощью одного-единственного фильтра мы выдаем карту признаков размером $H \times W \times 1$.

Ядро 3×3 перемещается по каждому каналу (например, $3 \times 3 \times 3$) изображения размером $H \times W$




Рис. 5.6 Дополненная свертка с одним фильтром производит наименьшую изменчивость выделения признаков

На рис. 5.7 показана свертка с дополнением на изображении размером $H \times W \times 3$ (три канала для RGB) с несколькими фильтрами C . Здесь мы выдаем карту признаков размером $H \times W \times C$.

Вы когда-нибудь видели стержневую свертку только с одной выводимой картой признаков, как изображено на рис. 5.6? Мой ответ –

нет. И это связано с тем, что один фильтр может научиться извлекать только один грубый признак. Это не будет работать для изображений! Даже если наши изображения представляют собой простые последовательности параллельных линий (один признак) и мы просто хотим подсчитать линии, то это все равно не сработает: мы не сможем контролировать то, какой признак фильтр научится извлекать. В указанном процессе остается определенная доля случайности, поэтому нам нужна некоторая избыточность, чтобы гарантировать, что достаточное число фильтров научится извлекать важные признаки.



Рис. 5.7 Дополненная свертка с несколькими фильтрами пропорционально увеличивает вариабельность в выделении признаков

Вы когда-нибудь производили одну карту признаков где-нибудь еще в сверточной нейросети? Ответ – да. Это было бы агрессивным сокращением за счет бутылочной свертки 1×1 . Бутылочная свертка 1×1 обычно используется для реиспользования признаков между разными свертками в сверточной нейросети.

Опять же, это предусматривает компромисс. С одной стороны, вы хотите объединить выгоды от выделения/усвоения признаков в одном месте сверточной нейросети с другим местом в сверточной нейросети (реиспользование признаков). Проблема в том, что реиспользование всех предыдущих карт признаков по числу и размеру создаст потенциально взрывной рост числа параметров. Результирующее увеличение отпечатка памяти и снижение скорости сведут выгоды на нет. Авторы архитектуры ResNet остановились на сокращении числа признаков как на наилучшем компромиссе между точностью, с одной стороны, и размером и производительностью – с другой.

Далее, взгляните на образец кодирования стержневого компонента модели ResNet в шаблоне идиоматического конструирования. Исходный код демонстрирует последовательный поток через слои, показанный ранее на рис. 5.3 для стержня:

- в слое Conv2D используется фильтр размером 7×7 , который служит для выделения признаков грубого уровня, и $\text{strides}=(2, 2)$ – для сведения признаков;

- в слое максимального сведения (MaxPooling) выполняется отбор с пониженной частотой, который служит для дальнейшего сокращения карт признаков.

Также стоит отметить, что ResNet была одной из первых моделей, в которой по традиции принято использовать пакетную нормализацию (BatchNormalization). В ранних традиционных подходах, которые теперь обозначаются как Conv-BN-RE, пакетная нормализация следовала за сверточными и плотными слоями. Напомним, что пакетная нормализация стабилизирует нейронные сети, перераспределяя выходы в слое в нормальное распределение. Это позволяет нейронной сети углубляться в слои, не сталкиваясь с проблемой исчезновения или взрыва градиента. Более подробную информацию см. в статье «Пакетная нормализация: ускорение тренировки глубокой сети путем сокращения внутреннего ковариантного сдвига» Сергея Иоффе и Кристиана Сегеди (Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, Sergey Ioffe and Christian Szegedy, <https://arxiv.org/abs/1502.03167>).

```
def stem(inputs):
    """ Построить стержневую сверточную группу
        inputs : входной вектор
    """
    outputs = ZeroPadding2D(padding=(3, 3))(inputs)
    outputs = Conv2D(64, (7, 7), strides=(2, 2), padding='valid')(outputs)
    outputs = BatchNormalization()(outputs)
    outputs = ReLU()(outputs)
    outputs = ZeroPadding2D(padding=(1, 1))(outputs)
    outputs = MaxPooling2D((3, 3), strides=(2, 2))(outputs)
    return outputs
```

Изображения 224×224 дополнены нулями (черный – без сигнала), став изображениями 230×230 до первой свертки

Первый сверточный слой, в котором используется крупный (грубый) фильтр


Сведенные карты признаков будут сокращены на 75 % с шагом 2×2

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для ResNet находится в репозитории на GitHub (<http://mng.bz/7jK9>).

5.2.3 ResNeXt

В моделях, появившихся после ResNet, использовалась традиция одинакового (same) дополнения, которое сводит слои к одной пошаговой свертке (сведение признаков) и шаговому максимальному сведению (отбор с пониженной частотой), сохраняя при этом ту же вычислительную сложность. Модель ResNeXt (<https://arxiv.org/abs/1512.03385>) компании Facebook AI Research (рис. 5.8), а также модель Inception компании Google Inc. ввели использование широких остаточных блоков в ученическом компоненте. Не волнуйтесь, если вы не знаете последствий широких и глубоких остаточных блоков; я расскажу о них

в главе 6. Здесь я просто хочу, чтобы вы знали, что появление дополнения внутри свертки появилось с ранними передовыми широкими остаточными моделями. Что касается использования в производстве, то архитектуры ResNeXt и другие широкие сверточные нейросети редко появляются за пределами устройств с ограниченной памятью; последующие разработки по размеру, скорости и точности являются более заметными.



Редукция размерности сокращает размер карт признаков на 75 %

Рис. 5.8 Стержневой компонент модели ResNeXt выполняет агрессивное сокращение карт признаков с помощью комбинированных признаков и максимального сведения

Обратите внимание, что при использовании традиционного правила одинакового дополнения отпала необходимость использовать слои ZeroPadding для поддержания размеров карт признаков.

Ниже приведен пример исходного кода для кодирования стержневой группы модели ResNeXt в шаблоне идиоматического конструирования. В этом примере вы видите контраст со стержневой группой модели ResNet; слои ZeroPadding отсутствуют и заменены на `padding='same'` для слоя Conv2D и слоя MaxPooling:

```
def stem(inputs):
    """ Построить стержневую сверточную группу
        inputs : входной вектор
    """
    outputs = Conv2D(64, (7, 7), strides=(2, 2), padding='same')(inputs)
    outputs = BatchNormalization()(outputs)
    outputs = ReLU()(outputs)
    outputs = MaxPooling2D((3, 3), strides=(2, 2), padding='same')(outputs)
    return outputs
```

Как и в VGG, вместо слоя
ZeroPadding2D используется
padding='same'

В последующих моделях фильтр размера 7×7 был заменен фильтром меньшего размера 5×5 , который имел меньшую вычислитель-

ную сложность. Сегодня по традиции широко принято использовать фильтр 5×5 , разложенный на два фильтра 3×3 , которые обладают одинаковой представительной мощностью при меньшей вычислительной сложности.

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для ResNeXt доступна в репозитории на GitHub (<http://mng.bz/ny6r>).

5.2.4 Xception

В настоящее время по традиции принято заменять один сверточный слой 5×5 двумя сверточными слоями 3×3 . Стержневой компонент модели Xception (<https://arxiv.org/abs/1610.02357>), показанный на рис. 5.9, является примером. Первая свертка 3×3 является пошаговой (сведением признаков) и производит 32 фильтра, а вторая свертка 3×3 не является шаговой и удваивает число выходных карт признаков до 64. Однако, помимо своей новизны в академических кругах, архитектура Xception не была принята в производстве и не получила дальнейшего развития последующими исследователями.

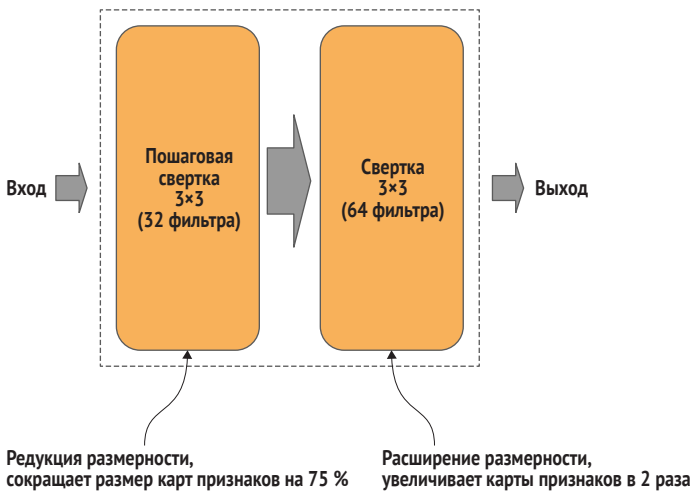


Рис. 5.9 Стержневая группа в архитектуре Xception

В этом примере для кодирования стержневой группы модели Xception в шаблоне идиоматического конструирования вы видите две свертки 3×3 (разложенная 5×5) и первую свертку с пошаговым выполнением (сведение признаков). За обеими свертками следует форма пакетной нормализации Conv-BN-RE:

```
def stem(inputs):
    """ Создать стержневую запись в нейронную сеть
        inputs : Тензор, поступающий на вход в нейросеть
    """
```

```

outputs = Conv2D(32, (3, 3), strides=(2, 2))(inputs)
outputs = BatchNormalization()(outputs)
outputs = ReLU()(outputs)

outputs = Conv2D(64, (3, 3), strides=(1, 1))(outputs)
outputs = BatchNormalization()(outputs)
outputs = ReLU()(outputs)
return outputs

```

Свертка 5×5,
разложенная на
две свертки 3×3

Полный вариант исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для архитектуры Xception находится в репозитории на GitHub (<http://mng.bz/5WzB>).

5.3 Предстержень

В 2019 году мы начали замечать появление случаев добавления предстержневой группы в стержневой компонент. Цель предстержня состоит в переносе в граф (модель) части или всей предобработки, которая выполнялась в потоке выше. До разработки предстержневого компонента предобработка данных выполнялась в отдельном модуле, а затем должна была реплицироваться при развертывании модели для (предсказательного) вывода на будущих примерах. Как правило, это делалось на CPU. Однако многие шаги предобработки могут заменяться графовыми операциями, а затем исполняться эффективнее на GPU, где модель обычно и развертывается.

Предстержни также организованы по принципу «подключи и играй» в том смысле, что их можно добавлять или удалять из существующих моделей и реиспользовать. Я представлю технические детали предстержней позже. Здесь я просто хочу обеспечить краткую сводку функций, обычно выполняемых предстержневой группой:

- предобработка:
 - адаптирование модели к другому размеру входных данных;
 - нормализация;
- обогащение (аугментация):
 - изменение размера и обрезка;
 - трансляционная и масштабная инвариантность.

На рис. 5.10 показано, как предстержневая группа добавляется в существующую модель. В целях прикрепления предстержня вы создаете новую пустую оберточную модель, добавляете предстержень, а затем добавляете существующую модель. На последнем шаге выходная форма из предстержневой группы должна соответствовать входной форме стержневого компонента существующей модели.

Ниже приведен пример типичного подхода к добавлению предстержневой группы в существующую модель. В этом исходном коде инстанцируется пустая оберточная модель `Sequential`. Затем добав-

ляется предстержневая группа, за которой следует существующая модель. Эта схема будет работать до тех пор, пока выходные тензоры совпадают с входными тензорами модели (например, (224, 224, 3)):

```
from tf.keras.layers.experimental.preprocessing import Normalization
```

```
def prestem(input_shape):
    ''' Предстержневые слои '''
    outputs = Normalization(input_shape=input_shape)
    return outputs
```

```
wrapper_model = Sequential() ← Создает пустую оберточную модель
```

```
wrapper_model.add(prestem(input_shape=(224, 224, 3)))
```

```
wrapper_model.add(model) ← Добавляет существующую модель в оберточную модель
```

Запускает оберточную модель с предстержнем



Рис. 5.10 Предстержень, добавленный в существующую модель, которая формирует новую оберточную модель

Далее мы объясним конструкцию ученического компонента, к которому будет присоединяться стержневой компонент.

5.4 Ученический компонент

Ученический компонент – это то место, где мы обычно выполняем усвоение признаков путем более детального выделения признаков. Этот процесс также именуется *усвоением представления*, или *усвоением преобразования* (поскольку усвоение преобразования зависит от задачи). Ученический компонент состоит из одной или нескольких

сверточных групп, и каждая группа состоит из одного или нескольких сверточных блоков.

Сверточные блоки собираются в группы на основе общего атрибута модельной конфигурации. Наиболее распространенными атрибутами сверточных групп в традиционных сверточных нейросетях являются число входных или выходных фильтров либо размер входных или выходных карт признаков. Например, в ResNet конфигурируемыми для группы атрибутами являются число сверточных блоков и число фильтров в расчете на блок.

На рис. 5.11 показана конфигурируемая сверточная группа. Как вы видите, сверточные блоки соответствуют метопараметру числа блоков в группе. Все, кроме последней группы, в большинстве передовых архитектур имеют одинаковое число выходных карт признаков, что соответствует метопараметру числа входных фильтров. Последний блок может изменять число карт признаков, выводимых группой (например, путем удвоения), что соответствует метопараметру числа выходных фильтров. Последний слой (обозначенный на изображении как блок сведения [признаков]) относится к группам, которые задерживают отбор с пониженной частотой, что соответствует метопараметру типа сведения.

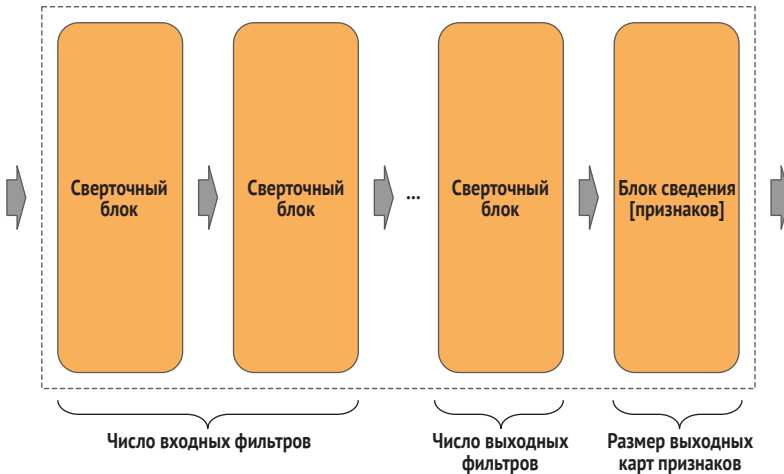


Рис. 5.11 Метопараметры сверточной группы для числа входных/выходных фильтров и размера выходных карт признаков

Следующий ниже исходный код представляет собой скелетную заготовку (и пример) для кодирования ученического компонента. В данном примере конфигурационный атрибут для групп передается в виде списка значений словаря, по одному на группу. Функция `learner()` прокручивает список групповых конфигурационных атрибутов в цикле; каждая итерация является групповыми параметрами (`group_params`) для соответствующей группы.

Соответственно, функция `group()` прокручивает блочные параметры (`block_params`) для каждого блока в группе в цикле. Затем функция `block()` строит блок в соответствии с переданными ей конфигурационными параметрами, специфичными для конкретного блока.

Как показано на рис. 5.11, конфигурируемыми атрибутами, передаваемыми методу `block()` в качестве именованных аргументов-списков, будет число входных фильтров (`in_filters`), число выходных фильтров (`out_filters`) и число сверточных слоев (`n_layers`). Если число входных и выходных фильтров одинаково, то обычно используется один-единственный именованный аргумент (`n_filters`):

```
def learner(inputs, groups):
    ''' Слои ученика
        inputs: входные тензоры (карты признаков)
        groups: блочные параметры для каждой группы
    '''
    outputs = inputs
    for group_params in groups:
        outputs = group(outputs, **group_params)
    return outputs

def group(inputs, **blocks):
    ''' групповые слои
        inputs: входные тензоры (карты признаков)
        blocks: блочные параметры для каждого блока
    '''
    outputs = inputs
    for block_params in blocks:
        outputs = block(**block_params)
    return outputs

def block(inputs, **params):
    ''' блочные слои
        inputs: входные тензоры (карты признаков)
        params: блочные параметры для блока
    '''
    ...
    return outputs

outputs = learner(outputs, [ {'n_filters': 128'},
                             {'n_filters': 128'},
                             {'n_filters': 256'} ])
```

Прокручивает значения словаря для каждого группового атрибута в цикле

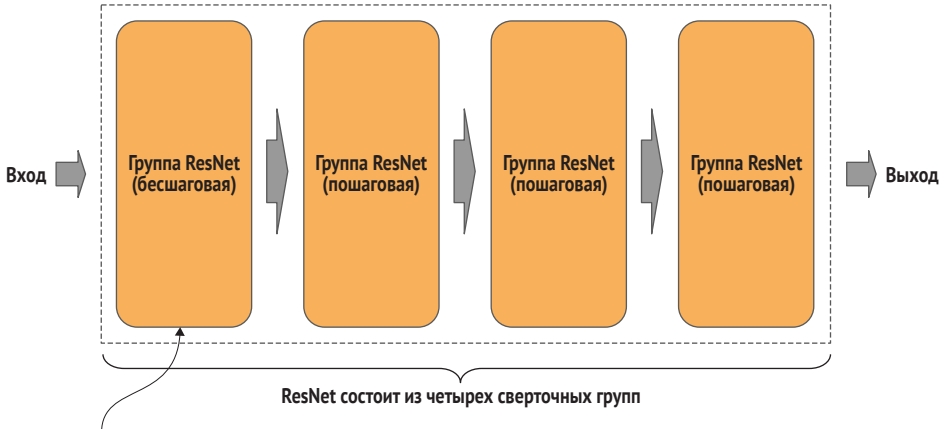
Прокручивает значения словаря для каждого блочного атрибута в цикле

Собирает ученический компонент, указывая число групп и фильтров в расчете на группу

5.4.1 ResNet

В ResNet50, 101 и 151 ученический компонент состоит из четырех сверточных групп. В первой группе бесшаговый сверточный слой используется для проекционной аббревиатуры в первом сверточном блоке, который на входе принимает данные из стержневого компонента. В остальных трех сверточных группах используется пошаго-

вый сверточный слой (сведение признаков) в проекционной аббревиатуре для первого сверточного блока. Эта компоновка показана на рис. 5.12.



В первой группе используется бесшаговый проекционный блок для первого блока, тогда как в последующих группах используется пошаговый проекционный блок

Рис. 5.12 В ученическом компоненте архитектуры ResNet первая группа начинается с бесшагового проекционного сокращенного блока

Теперь мы рассмотрим пример применения скелетной заготовки для кодирования ученического компонента архитектуры ResNet50. Обратите внимание, что в функции `learner()` мы вытолкнули первую группу конфигурационных атрибутов. В данном приложении это было сделано по той причине, что первая группа начинается с бесшаговой проекционной аббревиатуры, тогда как во всех остальных группах используется пошаговая проекционная аббревиатура. В качестве альтернативы можно было бы использовать конфигурационный атрибут, чтобы указывать, что первый остаточный блок является либо не является пошаговым, и исключить особый случай (кодирование отдельной блочной конструкции).

```
def learner(inputs, groups):
    """ Строит ученика
        inputs: данные на входе в ученика
        groups: групповые параметры в расчете на группу
    """
    outputs = inputs
    group_params = groups.pop(0)
    outputs = group(outputs, **group_params, strides=(1, 1))
    for group_params in groups:
        outputs = group(outputs, **group_params, strides=(2, 2))
    return outputs
```

Первая остаточная группа не является пошаговой

Оставшиеся остаточные группы принято делать пошаговыми

В то время как модели ResNet продолжают использоваться сегодня в качестве стоковой модели для магистральных применений классифицирования изображений, стандартом является 50-слойная сеть ResNet50, изображенная на рис. 5.13. При 50 слоях модель обеспечивает высокую точность при разумных размерах и производительности. Более крупные сети на 101 и 151 слое обеспечивают лишь незначительное повышение точности, но при значительном увеличении размера и снижении производительности.

Каждая группа начинается с остаточного блока с линейно-проекционной аббревиатурой, за которым следует один или несколько остаточных блоков с отождествляющей аббревиатурой. Все остаточные блоки в группе имеют одинаковое число выходных фильтров. Каждая группа по очереди удваивает число выходных фильтров, а остаточный блок с линейно-проекционной аббревиатурой удваивает число фильтров от входа до группы.

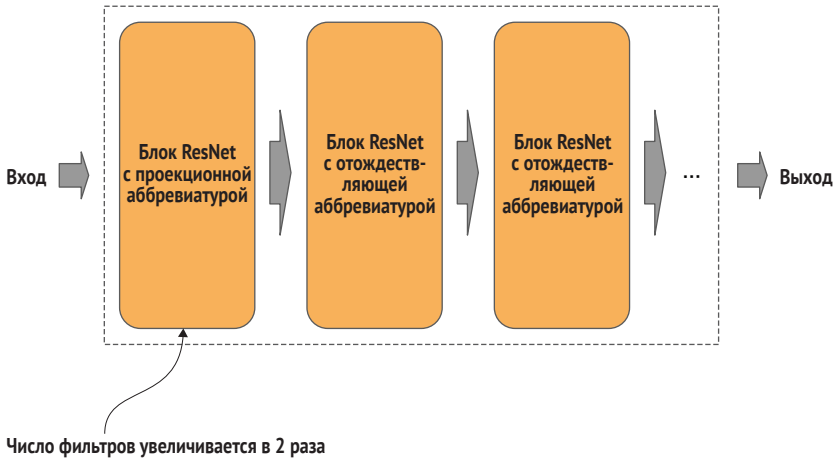


Рис. 5.13 В групповой макроархитектуре ResNet в первом блоке используется проекционная аббревиатура, а в остальных блоках используется отождествляющая связь

Модели ResNet (например, 50, 101, 152) состоят из четырех сверточных групп; выходные фильтры для четырех групп подчиняются традиционному правилу удвоения, начиная с 64, затем 128, 256 и, наконец, 512. Традиционное число (50) относится к числу сверточных слоев, которое определяет число сверточных блоков в каждой сверточной группе.

Ниже приведен пример применения скелетной заготовки для кодирования сверточной группы архитектуры ResNet50. Для функции `group()` мы выталкиваем конфигурационные атрибуты первого блока, которые, как мы знаем, для архитектуры ResNet являются проекционным блоком, а затем перебираем в цикле остальные блоки в качестве блоков идентификации:

```
def group(inputs, blocks, strides=(2, 2)):
    """ Построить остаточную группу
        inputs: данные на входе в группу
        blocks: блочные параметры для каждого блока
        strides: является или нет проекционный блок пошаговой сверткой
    """
    outputs = inputs
    block_params = blocks.pop(0)
    outputs = projection_block(outputs, strides=strides, **block_params)

    for block_params in blocks:
        outputs = identity_block(outputs, **block_params)
    return outputs
```

В первом блоке в остаточной группе используется линейно-проекционная аббревиатурная связь

В остальных блоках используется отождествляющая аббревиатурная связь

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для ResNet находится в репозитории на GitHub (<http://mng.bz/7jK9>).

5.4.2 DenseNet

Ученический компонент в DenseNet (<https://arxiv.org/abs/1608.06993>) состоит из четырех сверточных групп, как показано на рис. 5.14. Каждая группа, за исключением последней группы, задерживает сведение до конца группы, в так называемом *переходном блоке*. Последняя сверточная группа не имеет переходного блока, так как за ней не следует ни одна группа. Карты признаков будут сводиться и разглаживаться задачным компонентом, поэтому нет необходимости (излишне) выполнять их сведение в конце группы. Этот шаблон откладывания окончательного сведения в последней группе на задачный компонент сегодня продолжает оставаться общепринятой традицией.

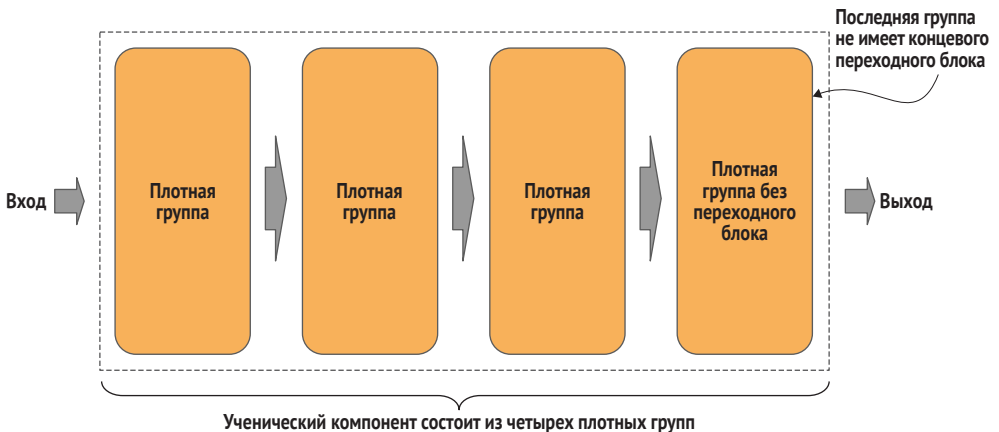


Рис. 5.14 Ученический компонент DenseNet состоит из четырех сверточных групп с отложенным сведением

Ниже приведен пример имплементации использования скелетной заготовки для кодирования ученического компонента в архитектуре DenseNet. Обратите внимание, что мы удаляем последние групповые конфигурационные атрибуты перед прокручиванием групп в цикле. Мы трактуем последнюю группу как особый случай, так как эта группа не заканчивается переходным блоком. В качестве альтернативы можно было бы использовать конфигурационный параметр, чтобы указать, что группа содержит переходный блок, исключив особый случай (то есть кодирование отдельной блочной конструкции). Параметр `reduction` задает величину сокращения размера карт признаков при отложенном сведении:

```
def learner(inputs, groups, reduction):
    """ Построить ученика
        inputs : данные на входе в ученика
        groups : множество чисел блоков в расчете на группу
        reduction : объем, на который сокращать (сжимать) карты признаков
    """
    outputs = inputs
    last = groups.pop()
    for group_params in groups:
        outputs = group(outputs, reduction, **group_params)
    outputs = group(outputs, last, reduction=None)
    return outputs
```

Вытаскивает параметры последней плотной группы и сохраняет на конец

Строит все плотные группы, кроме последней с посредническим переходным блоком

Добавляет последнюю плотную группу без переходного блока

Давайте посмотрим на сверточную группу в сети DenseNet (рис. 5.15). Она состоит всего из двух типов сверточных блоков. Первые блоки являются блоками DenseNet для усвоения признаков, а последний блок является переходным блоком для сокращения размера карт признаков перед следующей группой, которая называется *фактором сжатия*.

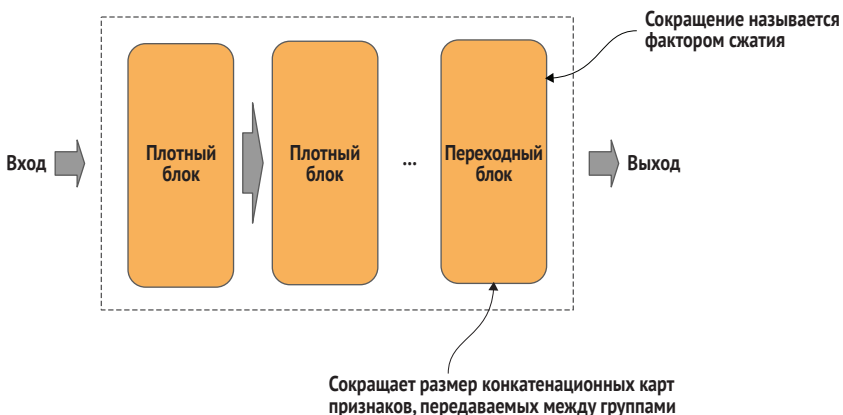


Рис. 5.15 Группа сети DenseNet состоит из последовательности плотных блоков и заключительного переходного блока для редукции размерности в выводимых картах признаков

Блок архитектуры DenseNet по существу является остаточным блоком, за исключением того, что вместо сложения (операция матричного сложения) отождествляющей связи с выходом он конкатенируется. В архитектуре ResNet информация из предыдущих входов передается только на один блок вперед. Используя конкатенацию, информация из карт признаков накапливается, и каждый блок передает всю накопленную информацию всем последующим блокам.

Это конкатенирование карт признаков приводит к продолжающемуся росту размера карт признаков и соответствующих параметров по мере углубления в слои. В целях контроля за ростом (его сокращения) переходный блок в конце каждого сверточного блока сжимает (сокращает) размер конкатенированных карт признаков. В противном случае, без сокращения, число подлежащих усвоению параметров существенно выросло бы по мере нашего углубления, что приводило бы к увеличению времени на тренировку без выгод от повышенной точности.

Ниже приведен пример имплементации для кодирования сверточной группы DenseNet:

```
def group(inputs, reduction=None, **blocks):
    """ Построить плотную группу
        inputs : тензор на входе в группу
        reduction : объем, на который следует сокращать карты признаков
        blocks : параметры для каждого плотного блока в группе
    """
    outputs = inputs
    for block_params in blocks:
        outputs = residual_block(outputs, **block_params)
    if reduction is not None:
        outputs = trans_block(outputs, reduction)
    return outputs
```

Строит группу плотно соединенных остаточных блоков

Строит посреднический переходный блок

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для DenseNet находится в репозитории на GitHub (<http://mng.bz/6N0o>). Далее мы объясним конструкцию задачного компонента, к которому будет подсоединяться ученический компонент.

5.5 Задачный компонент

Задачный компонент – это то место, где мы обычно выполняем усвоение задач. В крупных традиционных сверточных нейросетях для классифицирования изображений этот компонент чаще всего состоит из двух слоев:

- *бутылочного слоя* – выполняет редукцию размерности окончательных карт признаков в латентном пространстве;

- *классификаторного слоя* – выполняет задачу, которую модель усваивает.

Результатом работы учебного компонента является окончательный редуцированный размер карт признаков (например, пиксели 4×4). Бутылочный слой выполняет окончательную редукцию размерности окончательных карт признаков, которые затем вводятся в классификаторный слой для классифицирования.

В оставшейся части этого раздела мы опишем задачный компонент в контексте классификатора изображений; мы называем его *классификационным компонентом*.

5.5.1 ResNet

Для ResNet50 число карт признаков равно 2048. Первый слой в классификаторном компоненте состоит из разглаживания карт признаков в 1-мерный вектор и из сокращения размера, например с использованием слоя `GlobalAveragePooling2D`. Этот слой разглаживания/сокращения также называется бутылочным слоем, как указывалось ранее. За бутылочным слоем следует плотный (Dense) слой, который выполняет классифицирование.

На рис. 5.16 изображен классификатор ResNet50. На вход в классификаторный компонент подаются окончательные карты признаков из учебного компонента (латентное пространство), которые затем передаются через слой `GlobalAveragePooling2D`, сокращающий размер каждой карты признаков до одного пиксела и разглаживающий ее в 1-мерный вектор (бутылочное горлышко). Выходные данные из этого бутылочного слоя передаются через плотный слой, где число узлов соответствует числу классов. Результатом является распределение вероятностей для всех классов, сплюснутых активацией софтмакс так, чтобы в сумме составлять 100 %.




Рис. 5.16 Классификаторная группа архитектуры ResNet

Ниже приведен пример кодирования этого подхода в классификаторный компонент, состоящий из слоя `GlobalAveragePooling2D` для

разглаживания и редукции размерности, за которым следует плотный слой для классифицирования:

```
def classifier(inputs, n_classes):
    """ Выходной классификатор
        inputs : тензор на входе в классификатор
        n_classes : число выходных классов
    """
    outputs = GlobalAveragePooling2D()(inputs)
    outputs = Dense(n_classes, activation='softmax')(outputs)
    return outputs
```

Использует глобальное среднее сведение для редукции и разглаживания карт признаков (латентное пространство) в 1-мерный признаковый вектор (бутылочный слой, или слой бутылочного горлышка)

Полносвязный плотный слой для окончательного классифицирования входных данных

Полная версия исходного кода на основе шаблона идиоматического конструирования с процедурным реиспользованием для ResNet доступна в репозитории на GitHub (<http://mng.bz/7jK9>).

5.5.2 Многослойный выход

В ранее развернутых производственных системах машинного обучения модели трактовались как независимые алгоритмы, и нас интересовал только окончательный результат (предсказание). Сегодня мы создаем не модели, а приложения, которые представляют собой консолидации или композиции моделей. Как следствие мы больше не трактуем задачный компонент как единый результат.

Вместо этого мы смотрим на него как на четырехэлементный результат в зависимости от того, как модель связана с другими моделями в приложении. Эти элементы таковы:

- выделение признаков:
 - высокая размерность (кодирование);
 - низкая размерность (вложение) – признаковый вектор;
- предсказание:
 - предсказательные преактивационные вероятности – мягкие целевые показатели;
 - постаktivационные выходы – твердые целевые показатели.

В последующих главах рассматриваются предназначения этих выходов (глава 9 посвящена автокодировщикам, глава 11 – переносу обучения, глава 14 – предлоговым задачам в конвейерах тренировки), а также вы увидите, что каждый слой в классификаторе имеет два параллельных выхода. В множественном выходе из традиционного классификатора, изображенного на рис. 5.17, как вы видите, данные на входе в задачный компонент также являются независимым выходом из модели, именуемым *кодировкой*. Затем кодировка проходит через глобальное среднее сведение с целью редукции размерности, что еще больше сокращает размер признаков, извлекае-

мых ученическим компонентом. Данные на выходе из глобального среднего сведения также являются независимым выходом модели, именуемым *вложением*.

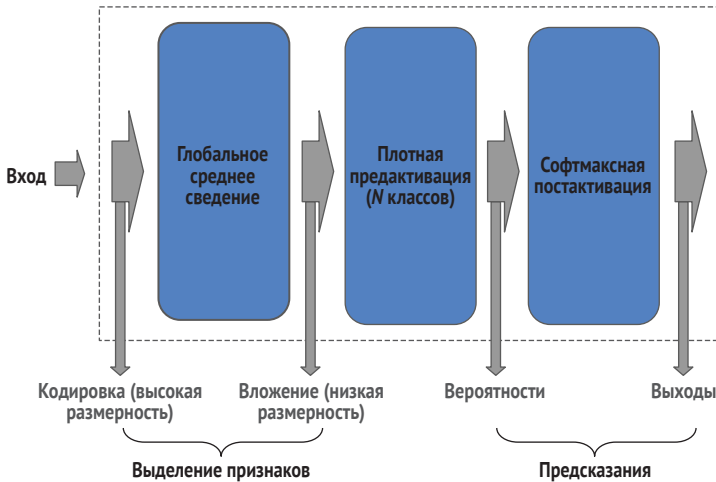


Рис. 5.17 Классификаторная группа классификатора с четырьмя выходами – два для коллективного использования функциональности выделения признаков и два для распределения вероятностей

Затем вложение передается в предактивационный плотный слой (перед активацией softmax). Выход из предактивационного слоя также является независимым выходом из модели, именуемым *распределением предактивационных вероятностей*. Это распределение вероятностей затем пропускается через softmax для постактивационного распределения вероятностей, что дает четвертый независимый выход из модели. Все эти выходы затем могут использоваться нижестоящими задачами.

Давайте опишем простой реально существующий пример использования задачного компонента с несколькими выходами: оценка стоимости ремонта по фотографии транспортного средства. Нам нужны оценки по двум категориям: стоимость ремонта незначительных повреждений, такие как вмятины и царапины, и стоимость ремонта серьезных повреждений, такие как повреждения при столкновении. Мы могли бы попробовать сделать это в одном-единственном задачном компоненте, который действует как регрессор, выводя действительное значение (стоимость в долларах), но мы на самом деле перегрузили бы задачный компонент во время тренировки, потому что он усваивает как крошечные значения (незначительный урон), так и крупные значения (серьезный урон). Во время тренировки широкое распределение в значениях, вероятно, будет препятствовать сходимости модели.

Подход состоит в том, чтобы решить поставленную задачу как два отдельных задачных компонента: один для незначительного урона

и один для крупного урона. Задачный компонент для незначительного урона будет усваивать только крошечные значения, а задачный компонент для крупного урона будет усваивать только крупные значения – поэтому оба задачных компонента должны во время тренировки сходиться.

Далее мы рассмотрим выходной уровень, который коллективно используем с двумя задачами. Относительно незначительных повреждений мы смотрим на крошечные предметы. Хотя мы не рассматриваем обнаружение объектов, историческая проблема классифицирования объектов с малыми объектами заключалась в том, что обрезанные карты признаков после сведения содержали слишком мало пространственной информации. Исправление заключалось в классифицировании объектов по картам признаков на более ранней свертке; тогда карты признаков имеют достаточный размер, чтобы при вырезании крошечного объекта оставалась пространственная информация, которой было бы достаточно для классифицирования объектов.

В нашем примере имеется аналогичная трудность. При незначительных повреждениях объекты (каждая вмятина) будут очень маленькими, и для их обнаружения понадобятся карты признаков более крупного размера. Поэтому для данной цели к задаче, которая выполняет оценивание незначительного урона, мы присоединяем многомерную кодировку, перед усреднением и сведением. С другой стороны, серьезные повреждения при столкновениях не требуют особых подробностей. Если на крыле есть вмятина, то его необходимо заменить, например, независимо от размера или расположения вмятины. Поэтому для этой цели к задаче, которая выполняет оценивание крупного урона, мы присоединяем низкоразмерное вложение, после усреднения и сведения. Рисунок 5.18 иллюстрирует этот пример.

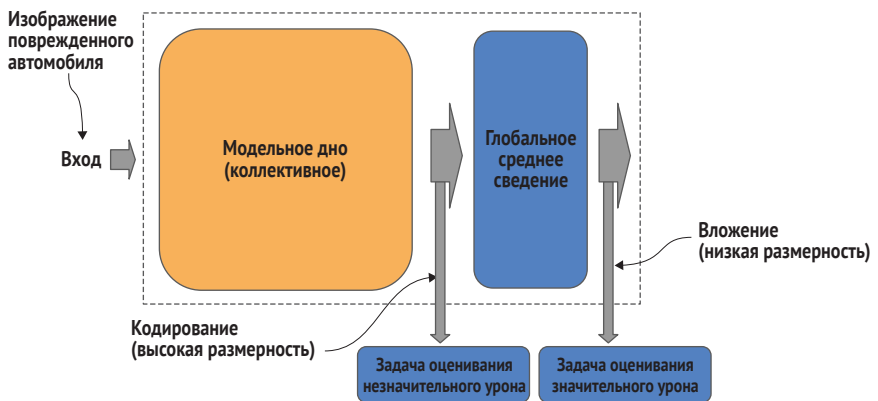


Рис. 5.18 Многозадачный компонент, в котором используется несколько выходов из коллективной модельной вершины для оценивания стоимости ремонта транспортного средства

Ниже приведен пример имплементации исходного кода для нескольких выходов для классификационного компонента. Выходные данные выделения признаков и предсказания имплементируются путем захвата тензорных данных на входе в каждый слой. В конце классификатора мы вместо одного выхода возвращаем кортеж из всех четырех выходов:

```
def classifier(inputs, n_classes):
    """ Выходной классификатор
        inputs : тензорные данные на входе в классификатор
        n_classes : число выходных классов
    """
    encoding = inputs  ← Высокоразмерное выделение признаков (кодировка)
    embeddings = GlobalAveragePooling2D()(inputs)
    probabilities = Dense(n_classes)(embeddings)  ← Предактивационные вероятности (мягкие метки)
    outputs = Activation('softmax')(outputs)  ← Постактивационные вероятности (твердые метки)
    return encoding, embeddings, probabilities, outputs
```

Низкоразмерное выделение признаков (вложение) → embeddings

Возвращает кортеж из всех четырех выходов → return encoding, embeddings, probabilities, outputs

5.5.3 SqueezeNet

В компактных моделях, в особенности для мобильных устройств, слой GlobalAveraging2D, за которым следует плотный (Dense) слой, заменяется слоем Conv2D с использованием софтмаксной активации. Число фильтров в слое Conv2D устанавливается равным числу классов, а затем следует слой GlobalAveraging2D для разглаживания по числу классов. Статья «SqueezeNet» Форреста Яндолы и соавт. (SqueezeNet, Forrest Iandola et al., <https://arxiv.org/pdf/1602.07360.pdf>) объясняет причину замены плотного слоя сверточным слоем: «Обратите внимание на отсутствие в архитектуре SqueezeNet полносвязных слоев; этот конструктивный выбор был сделан под влиянием архитектуры NiN (Лин и соавт., 2013)».

На рис. 5.19 приведен пример кодирования архитектуры SqueezeNet, в которой этот подход применяется к классификационному компоненту. Архитектура SqueezeNet была разработана в 2016 году в совместной группе DeepScale Калифорнийским университетом в Беркли и Стэнфордским университетом для мобильных устройств и в то время была передовой.

Как вы видите, вместо плотного слоя в нем используется свертка 1×1 , в которой число фильтров соответствует числу классов (C). Таким образом, свертка 1×1 усваивает распределение вероятностей классов вместо проекции входных карт признаков. Каждая (из C) результирующая карта признаков затем сводится в одно действительное значение для получения распределения вероятностей, и все они разглаживаются в 1-мерный выходной вектор. Например, если каждая карта

признаков, выдаваемая сверткой 1×1 , имеет размер 3×3 (9 пикселей), то пиксел с наибольшим значением выбирается в качестве вероятности соответствующего класса. 1-мерный вектор затем сплющивается софтмаксной активацией, в результате чего все вероятности в сумме составляют 1.

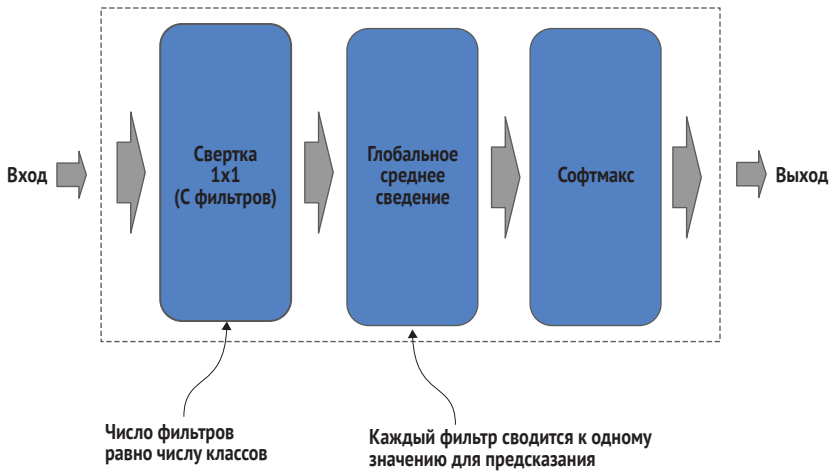


Рис. 5.19 Классификаторная группа архитектуры SqueezeNet

Давайте сопоставим этот подход с подходом на основе глобального среднего сведения и плотного слоя, который мы обсуждали в крупных передовых моделях. Допустим, что размер окончательных карт признаков составляет 3×3 (9 пикселей). Затем мы усредняем 9 пикселей до одного-единственного значения и выполняем распределение вероятностей на основе одного среднего значения для каждой карты признаков. В методе, используемом в архитектуре SqueezeNet, сверточный слой, который выполняет распределение вероятностей, видит 9-пиксельную карту признаков (в отличие от усредненного одиночного пиксела) и имеет больше пикселей для усвоения распределения вероятностей. По-видимому, это было выбрано авторами архитектуры SqueezeNet, чтобы компенсировать меньший объем выделения/усвоения признаков с меньшим модельным дном.

Ниже приведен пример кодирования классификационного компонента архитектуры SqueezeNet. В данном примере число фильтров для слоя Conv2D равно числу классов (`n_classes`), за которыми затем следует слой `GlobalAveragePooling2D`. Поскольку этот слой является статическим (неусваиваемым) слоем, у него нет активационного параметра, поэтому после него мы должны разместить слой софтмаксной активации:

```
def classifier(inputs, n_classes):
    ''' Построить классификатор
    inputs : тензорные данные на входе в классификатор
```

```

    n_classes: число выходных классов
    ...
    encoding = Conv2D(n_classes, (1, 1), strides=1,
                      activation='relu', padding='same')(inputs)

    embedding = GlobalAveragePooling2D()(outputs)
    outputs = Activation('softmax')(outputs)
    return outputs

```

Задаёт число фильтров, равное числу выходных классов

Сокращает каждую карту признаков (класс) до одного-единственного значения (мягкой метки)

Использует софтмакс для втискивания всех вероятностей классов так, чтобы в сумме они составляли 100 %

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для SqueezeNet находится в репозитории на GitHub (<http://mng.bz/XYmv>).

5.6 За пределами компьютерного зрения: обработка естественного языка

Как упоминалось в главе 1, шаблоны конструирования, которые я объясняю в контексте компьютерного зрения, имеют сопоставимые принципы и шаблоны в обработке естественного языка и структурированных данных. В целях ознакомления с тем, как шаблон процедурного конструирования может применяться к обработке естественного языка (NLP), давайте взглянем на пример из одного из видов обработки ЕЯ – понимания естественного языка (NLU).

5.6.1 Понимание естественного языка

Давайте начнем с рассмотрения общей модельной архитектуры для понимания ЕЯ на рис. 5.20. В понимании ЕЯ модель учится понимать текст и выполнять задачу, основываясь на таком понимании. Примеры задач включают классифицирование текста, анализ настроений и выделение сущностей.

Мы могли бы классифицировать медицинские документы по типу, например идентифицируя каждый из них как рецепт, записку врача, заявление с претензией или другой документ. В случае анализа настроений задача может стоять в том, чтобы определять, был отзыв благоприятным или неблагоприятным (двоичная классификация) либо ранжировать от неблагоприятного к благоприятному (мультиклассовая классификация). В случае выделения сущностей наша задача может состоять в том, чтобы извлекать жизненно важные показатели здоровья из результатов лабораторных исследований и заметок врача/медсестры.

Модель понимания ЕЯ (NLU) разбивается на те же компоненты, которые составляют все модели глубокого обучения: стержень, ученика

и задачу. Различия заключаются в том, что собственно происходит в каждом компоненте.

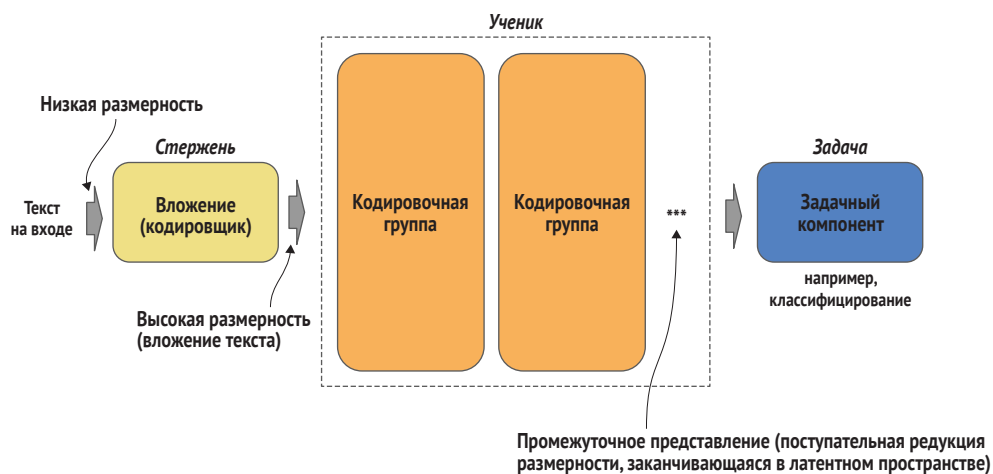


Рис. 5.20 Как и все модели глубокого обучения, модели понимания ЕЯ состоят из стержневого, ученического и задачного компонентов. Различия заложены внутри каждого компонента

В модели понимания ЕЯ стержень состоит из кодировщика. Его цель состоит в том, чтобы преобразовывать строковое представление текста в численный вектор, именуемый *вложением*. Это вложение имеет более высокую размерность, чем строковые входные данные, и содержит более богатую контекстную информацию о словах, символах или предложениях. Стержневой кодировщик на самом деле является еще одной моделью, которая была преднатренирована. Думайте о стержневом кодировщике как о словаре. Для каждого слова, низкой размерности, он выдает все возможные смыслы, высокую размерность. Распространенным примером вложения является вектор из N размерностей, в котором каждый элемент представляет еще одно слово, а значение указывает, насколько тесно это слово связано с другим словом.

Затем вложения передаются ученическому компоненту. В модели понимания ЕЯ (NLU) ученик состоит из одной или нескольких кодировочных групп, которые, в свою очередь, состоят из одного или нескольких кодировочных блоков. Каждый из этих блоков основан на шаблоне конструирования, таком как блок внимания в трансформерной модели, а сборка блоков и групп основана на конструктивных принципах кодировочных шаблонов.

Вы, вероятно, заметили, что и стержень, и ученик ссылаются на кодировщик. Они не обозначают одинаковый тип кодировщика в каждом компоненте. Наличие одного и того же имени для двух разных вещей может немного дезориентировать, поэтому я поясню. Когда мы говорим о кодировщике, который генерирует вложения, мы бу-

дем называть его *стержневым кодировщиком*; в противном случае мы имеем в виду кодировщик в ученике.

Предназначение кодировщика в ученике состоит в конвертировании вложений в низкоразмерное отображение/представление смысла текста, которое называется *промежуточным представлением*. Это сравнимо с усвоением существенных признаков в изображении в сверточной нейросети.

Задачный компонент удивительно похож на свой визави компьютерного зрения. Промежуточное представление разглаживается в 1-мерный вектор и сводится. Сведенное представление для классифицирования и семантического анализа передается в софтваксный плотный слой для предсказания распределения вероятностей по всем классам или семантического ранжирования.

Что касается выделения сущностей, то задачный компонент сопоставим с задачным компонентом для модели обнаружения объектов; вы усваиваете две задачи: классифицирование выделенной сущности и точную настройку границы местоположения в тексте выделенной сущности.

5.6.2 Трансформерная архитектура

Теперь давайте рассмотрим еще один аспект современных моделей понимания ЕЯ (NLU), который сопоставим с передовыми в компьютерном зрении. Как упоминалось в главе 1, серьезные изменения в понимании ЕЯ произошли с внедрением в 2017 году трансформерной модельной архитектуры от Google Brain и соответствующей статьи «Внимание – это все, что вам нужно» Ашишха Васвани и соавт. (<https://arxiv.org/abs/1706.03762>). Трансформерная архитектура решила сложную проблему понимания ЕЯ: как манипулировать текстовыми последовательностями, которые по существу сопоставимы с временными рядами, то есть смысл зависит от порядка следования слов. Ранее в трансформерной архитектуре все модели понимания ЕЯ имплементировались в виде рекуррентных нейронных сетей (RNN), которые удерживали порядок следования текста и усваивали важность (долговременная память) или неважность (кратковременная память) слов.

Трансформаторная модель ввела новый механизм под названием «*внимание*», который преобразовывал модели понимания ЕЯ из временных рядов в пространственную модель. Вместо того чтобы рассматривать слова, или символы, или предложения как последовательность, мы берем фрагмент слов и представляем их пространственно, как изображение. Модель учится извлекать существенные признаки из контекста. Механизм внимания действует аналогично отождествляющей связи в остаточной сети. Он добавляет внимание – вес – в более важные контексты.

На рис. 5.21 показан блок внимания в трансформерной архитектуре. На вход в блок подается набор карт контекста, сопоставимых

с картами признаков из предыдущего блока. Механизм внимания добавляет веса тем частям контекстного блока, которые важнее для понимания контекста (здесь указывается то, на что следует обратить внимание). Карты контекста внимания затем передаются в слой подачи в прямом направлении, который выдает следующий ниже набор карт контекста.

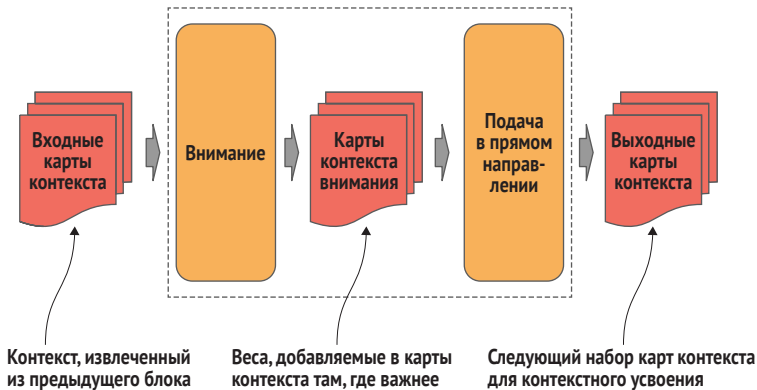


Рис. 5.21 Блок внимания добавляет веса в ту часть контекста, которая является более важной для понимания текста

В следующей главе мы рассмотрим широкие сверточные нейронные сети, шаблон конструирования, который сосредоточивается не на более глубоких слоях, а на более широких.

Резюме

- Использование шаблона конструирования для разработки и кодирования сверточной нейросети делает модели понятнее, экономит время, обеспечивает отражение моделью лучших передовых образцов практики и легко воспроизводится другими.
- В шаблоне процедурного конструирования используется принцип реиспользования, пришедший из строительства программно-информационного обеспечения, который широко применяется инженерами ПО на практике.
- Макроархитектура состоит из стержневого, ученического и задачного компонентов, которые определяют поток через модель и где/какой тип усвоения происходит.
- Микроархитектура состоит из групповых и блочных шаблонов конструирования, которые определяют то, как модель выполняет усвоение.
- Предназначение предстержневой группы – расширять существующие (преднатренированные) модели для вышестоящей преобразования данных, обогащения изображений и адаптации к другим

развернутым средам. Имплементирование предстержней по принципу «подключи и играй» обеспечивает MLOps¹ для развертывания моделей без сопутствующего вышестоящего исходного кода.

- Предназначение задачного компонента задачи состоит в том, чтобы усваивать специфичную для модели задачу из латентного пространства, кодируя усвоение во время выделения признаков и усвоения представления.
- Предназначение многослойного вывода состоит в том, чтобы расширять межсоединенность между моделями для решения сложных задач в наиболее эффективном ключе при сохранении целевых критериев производительности.
- Механизм внимания в трансформере обеспечил метод последовательного усвоения существенных признаков в ключе, сопоставимом с компьютерным зрением, без необходимости в рекуррентной сети.

¹ MLOps – практика применения наработок DevOps с целью автоматизации, управления и аудита рабочих потоков машинного обучения (ML). – Прим. перев.

Широкие сверточные нейронные сети

Эта глава охватывает следующие ниже темы:

- введение шаблона конструирования широкого сверточного слоя;
- понимание преимуществ широких слоев по сравнению с глубокими слоями;
- разложение микроархитектурных шаблонов с целью снижения вычислительной сложности;
- кодирование некогда передовых сверточных моделей с использованием шаблона процедурного конструирования.

Ранее в центре нашего внимания находились сети с более глубокими слоями, блочными слоями и аббревиатурами в остаточных сетях для задач, связанных с изображениями, таких как классифицирование, локализация объектов и сегментация изображений. Теперь мы взглянем на сети с широкими, а не с глубокими сверточными слоями. Начиная с 2014 года вместе с Inception v1 (GoogLeNet) и 2015 года с ResNeXt и Inception v2 нейросетевые конструкции переместились в широкие слои, уменьшив необходимость движения вглубь слоев. По сути, широкослойная конструкция означает параллельное выполнение нескольких сверток с последующей конкатенацией их выходных данных. Напротив, более глубокие слои имеют последовательные свертки и агрегируют свои выходы.

Так что же привело к экспериментам с шаблонами широкослойного конструирования? В то время исследователи понимали, что для повышения точности моделей им необходимо больше емкости. Если

быть точнее, им необходимо было иметь сверхъемкость, чтобы иметь избыточность.

Ранняя работа с VGG (<https://arxiv.org/pdf/1409.1556.pdf>) и ResNet v1 (<https://arxiv.org/abs/1512.03385>) продемонстрировала, что емкость, добавляемая более глубокими слоями, действительно повышала точность. Например, AlexNet (2012) была первой заявленной сверточной нейронной сетью, а также победителем в конкурсе ILSVRC, добившись ошибки в категории топ-5 в размере 15.3 %, что на 10 % лучше, чем у победителя 2011 года. ZFNet была построена поверх AlexNet и стала победителем 2013 года с ошибкой в топ-5 14.8 %. Затем, в 2014 году, VGG продвинулась глубже по уровням, первой заняв второе место с частотой ошибок в топ-5, составившей 7.3 %, тогда как ResNet пошла еще дальше в 2015 году и заняла первое место с частотой ошибок в топ-5 на уровне 3.57 %.

Но все эти конструкции столкнулись с препятствиями, которые ограничивали глубину слоев и, следовательно, возможность увеличения емкости. Серьезной проблемой были исчезающие и взрывающиеся градиенты. По мере добавления в модель более глубоких слоев веса в этих более глубоких слоях с большей вероятностью становились либо слишком малыми (исчезающими), либо слишком большими (взрывающимися). Во время тренировки модели выходили из строя, подобно сбоям компьютерной программы.

Внедрение пакетной нормализации в 2015 году частично решило эту проблему. Авторы эпохальной статьи (<https://arxiv.org/abs/1502.03167>) выдвинули гипотезу о том, что перераспределение весов во время тренировки в каждом слое в нормальное распределение решило бы проблему слишком малых или слишком больших весов в более глубоких слоях. Другие исследователи подтвердили эту гипотезу, и пакетная нормализация стала традиционной практикой, которая продолжается и по сей день.

Но при большем углублении внутрь слоев по-прежнему оставалась еще одна проблема: запоминание. Оказалось, что более глубокие слои, которые добавляли сверхъемкость для повышения точности, с большей вероятностью запоминали данные, чем более мелкие слои. То есть при сверхъемкости примеры из тренировочных данных могут закрепляться в узлах вместо обобщения на основе тренировочных данных. Когда во время тренировки вы видите повышение точности на тренировочных данных, но резкое падение точности на примерах, не наблюдавшихся во время тренировки, мы говорим, что модель *переподогнана*. И это была переподгонка, которая указывала на то, что модели скорее запоминали, чем учились. Добавление некоторого шума в более глубокие слои, такого как отсев и гауссов шум, уменьшало запоминание, но не устраняло его.

Но что, если увеличить емкость, сделав свертки вместо этого шире в более мелких слоях? Эта дополнительная емкость уменьшила бы необходимость углубляться в слои, где происходило запоминание. Возьмем, к примеру, ResNeXt, которая заняла первое место в конкур-

се ILSVRC 2016 года. Она заменила последовательную свертку в остаточном блоке параллельной сверткой, чтобы увеличить емкость в мелких слоях.

В этой главе рассматривается эволюция в конструкции широких слоев, начиная с принципа нативного модуля Inception, который был модернизирован в архитектуре Inception v1, а затем продолжен усовершенствованиями широкослойных блоков в Inception v2 и v3. Мы также рассмотрим параллельную эволюцию в конструкции широких слоев в ResNeXt от Facebook AI Research и широкой остаточной сети от Paris Tech.

6.1 Inception v1

Архитектура *Inception v1* (<https://arxiv.org/abs/1409.4842>), которая выиграла конкурс ILSVRC 2014 года на обнаружение объектов под своим первоначальным названием GoogLeNet, представила модуль Inception. Указанный сверточный слой имеет параллельные свертки фильтров разных размеров, при этом данные на выходе из каждой свертки конкатенируются вместе. Здесь идея заключалась в том, что вместо того, чтобы пытаться выбирать наилучший размер фильтра для слоя, каждый слой имеет несколько размеров фильтров параллельно, и слой «усваивает размер, который является наилучшим».

Например, допустим, что вы разработали модель с несколькими сверточными слоями, но вы не знаете, какой размер фильтра даст вам наилучший результат. Допустим, вы хотите знать, какой из трех размеров – 3×3 , 5×5 или 7×7 – даст вам наилучшую точность. В целях сравнения точности вам нужно будет создать три версии модели, по одной для каждого размера фильтра, и натренировать каждую из них. Но допустим, теперь вы хотите узнать наилучший размер фильтра на каждом слое. Возможно, первый слой должен иметь размер 7×7 , следующий 5×5 , а оставшийся 3×3 (или будет какая-либо другая комбинация). В зависимости от глубины это может означать сотни или даже тысячи возможных комбинаций. Тренировка каждой комбинации вылилась бы в огромное предприятие.

Вместо этого конструкция модуля Inception (начального модуля) решила эту задачу, пропустив каждую карту признаков через параллельные свертки разных размеров фильтра в каждом сверточном слое. Это нововведение позволило модели усваивать соответствующий размер фильтра с помощью одной-единственной версии и тренировки экземпляра модели.

6.1.1 Нативный модуль Inception

На рис. 6.1 показан нативный модуль Inception, который демонстрирует этот подход.

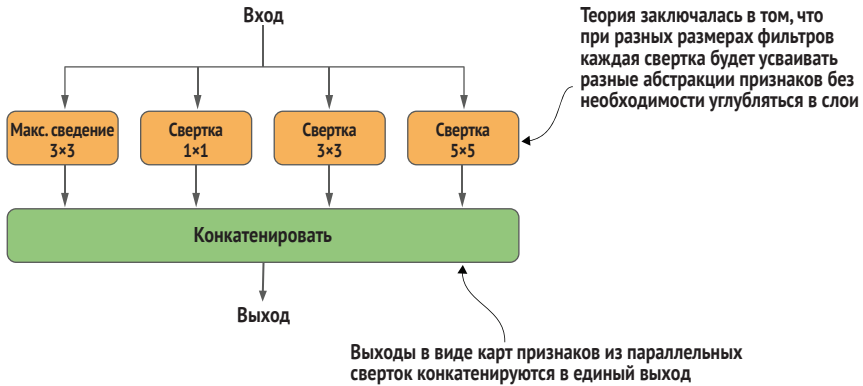


Рис. 6.1 Нативный модуль Inception, который был теоретической базой для экспериментов с разными вариантами модуля Inception

Нативный модуль Inception представляет собой сверточный блок. Данные, поступающие на вход блока, передаются через четыре ветви: слой сведения для редукции размерности и слои сверток 1×1 , 3×3 и 5×5 . Данные на выходе из сведения и других сверточных слоев затем конкатенируются вместе.

Разные размеры фильтров обеспечивают разные уровни детализации. Свертка 1×1 улавливает мелкие детали признаков, тогда как 5×5 улавливает более абстрактные признаки. Указанный процесс можно увидеть на примере имплементации нативного модуля Inception. Данные, поступающие на вход из предыдущего блока (слоя) x , разветвляются и передаются через слой максимального сведения, свертки 1×1 , 3×3 и 5×5 , которые затем конкатенируются вместе:

Модуль Inception ветвится там, где x является предыдущим слоем

```
x1 = MaxPooling2D((3, 3), strides=(1,1), padding='same')(x)
x2 = Conv2D(64, (1, 1), strides=(1, 1), padding='same', activation='relu')(x)
x3 = Conv2D(96, (3, 3), strides=(1, 1), padding='same', activation='relu')(x)
x4 = Conv2D(48, (5, 5), strides=(1, 1), padding='same', activation='relu')(x)
```

```
output = Concatenate()([x1, x2, x3, x4])
```

Конкатенирует выходы из четырех ветвей

Установив значение `padding='same'`, сберегаются размерности высоты и ширины данных на входе. Это позволяет конкатенировать вместе соответствующие данные на выходе из каждой ветви. Например, если бы на входе было 256 карт признаков размером 28×28 , то размерности в слоях ветвления были бы следующими, где ? является местоополнителем для размера пакета:

```
x1 (pool)      : (?, 28, 28, 256)
x2 (1x1)       : (?, 28, 28, 64)
x2 (3x3)       : (?, 28, 28, 96)
x3 (5x5)       : (?, 28, 28, 48)
```

После конкатенации на выходе будет следующее:

x (concat) : (?, 28, 28, 464)

Теперь давайте посмотрим на то, как мы добрались до этих цифр. Во-первых, как свертка, так и максимальное сведение являются бесшаговыми (а значит, что они имеют шаг 1), поэтому нет отбора карт признаков с пониженной частотой. Во-вторых, поскольку мы установили `padding='same'`, у нас не будет потери в пиксельной ширине/высоте по краям. Таким образом, размер выводимых карт признаков будет таким же, как и на входе, отсюда и 28×28 на выходе.

Теперь давайте посмотрим на ветвь максимального сведения, которая выдает такое же число входящих карт признаков, поэтому мы получаем 256. Число карт признаков для трех сверточных ветвей равно числу фильтров, поэтому оно будет 64, 96, 48. Тогда если сложить все карты признаков из ветвей для конкатенации, то мы получим 464.

Сводная информация (`summary()`) для нативного модуля Inception показывает 544 000 тренируемых параметров:

max_pooling2d_1 (MaxPooling2D)	(None, 28, 28, 256)	0	input_1[0][0]
conv2d_1 (Conv2D)	(None, 28, 28, 64)	16448	input_1[0][0]
conv2d_2 (Conv2D)	(None, 28, 28, 96)	221280	input_1[0][0]
conv2d_3 (Conv2D)	(None, 28, 28, 48)	307248	input_1[0][0]
concatenate_1 (Concatenate)	(None, 28, 28, 464)	0	max_pooling2d_1[0][0] conv2d_1[0][0] conv2d_2[0][0] conv2d_3[0][0]

=====

Total params: 544,976
Trainable params: 544,976

Если бы аргумент `padding='same'` был опущен (по умолчанию используется значение `padding='valid'`), то формы вместо этого выглядели бы следующим образом:

x1 (pool) : (?, 26, 26, 256)
x2 (1x1) : (?, 28, 28, 64)
x2 (3x3) : (?, 26, 26, 96)
x3 (5x5) : (?, 24, 24, 48)

Поскольку размерности ширины и высоты не совпадают, то если бы вы попытались конкатенировать эти слои, то получили бы следующую ниже ошибку¹:

¹ Ошибка значения: для слоя конкатенирования требуются входы с совпадающими формами, за исключением оси concat. Получены входные формы: [(None, 26, 26, 256), (None, 28, 28, 64), (None, 26, 26, 96), (None, 24, 24, 48)]. – Прим. перев.

ValueError: A Concatenate layer requires inputs with matching shapes except
→ for the concat axis. Got inputs shapes: [(None, 26, 26, 256), (None, 28,
→ 28, 64), (None, 26, 26, 96), (None, 24, 24, 48)]

Нативный модуль Inception был теоретическим принципом авторов архитектуры Inception v1. Когда авторы отправились на конкурс ILSVRC, они разложили и переработали этот модуль с помощью конструкции бутылочного остаточного блока и дали ему название «модуль Inception v1». Этот модуль поддерживал точность и был вычислительно менее затратным для тренировки.

6.1.2 Модуль Inception v1

Архитектура Inception v1 ввела дальнейшую редукцию размерности за счет добавления бутылочной свертки 1×1 в ветви сведения, 3×3 и 5×5 . Указанная редукция размерности сократила совокупную вычислительную сложность почти на две трети.

В этом месте вы, возможно, спросите, зачем использовать свертку 1×1 ? Как может 1-пиксельный фильтр, сканируемый по каждому каналу, усваивать какие-либо признаки? Использование свертки 1×1 действует подобно связующему коду. Свертки 1×1 применяются либо для расширения, либо для сокращения числа каналов на выходе при сбережении размера (формы) канала. Расширение числа каналов называется *линейной проекцией*; мы обсуждали ее в разделе 5.3.1.

Сокращение, также именуемое *бутылочным горлышком*, используется для сокращения числа каналов между входом в блок и входом в сверточный слой. Линейно-проекционная и бутылочная свертки аналогичны отбору с повышенной и пониженной частотой, за исключением того, что мы расширяем или сокращаем не *размер* каналов, а их *число*. В данном случае, поскольку мы сокращаем число каналов, мы могли бы сказать, что сжимаем данные – и именно поэтому мы используем термин «*редукция размерности*». Мы могли бы сделать это с помощью статического алгоритма или, как в данном случае, *усвоить оптимальный метод сокращения числа каналов*. Это аналогично максимальному сведению и сведению признаков; при максимальном сведении мы используем статический алгоритм сокращения размера каналов, а при сведении признаков *усваиваем оптимальный метод сокращения размера*.

На рис. 6.2 показан блок (модуль) Inception v1. Ветвям 3×3 и 5×5 предшествует бутылочная свертка 1×1 , и за ветвью сведения тоже следует бутылочная свертка 1×1 .

А вот пример блока (модуля) Inception v1, в котором ветви сведения, свертки 3×3 и 5×5 имеют дополнительную бутылочную свертку 1×1 :

Inception ветвится там, где x является предыдущим слоем

```
x1 = MaxPooling2D((3, 3), strides=(1,1), padding='same')(x)
x1 = Conv2D(64, (1, 1), strides=(1, 1), padding='same',
    ➔ activation='relu')(x1)
x2 = Conv2D(64, (1, 1), strides=(1, 1), padding='same', activation='relu')(x)
x3 = Conv2D(64, (1, 1), strides=(1, 1), padding='same', activation='relu')(x)
x3 = Conv2D(96, (3, 3), strides=(1, 1), padding='same',
    ➔ activation='relu')(x3)
x4 = Conv2D(64, (1, 1), strides=(1, 1), padding='same', activation='relu')(x)
x4 = Conv2D(48, (5, 5), strides=(1, 1), padding='same',
    ➔ activation='relu')(x4)
```

$x = \text{Concatenate}([x1, x2, x3, x4])$ ← Конкатенирует карты признаков из ветвей

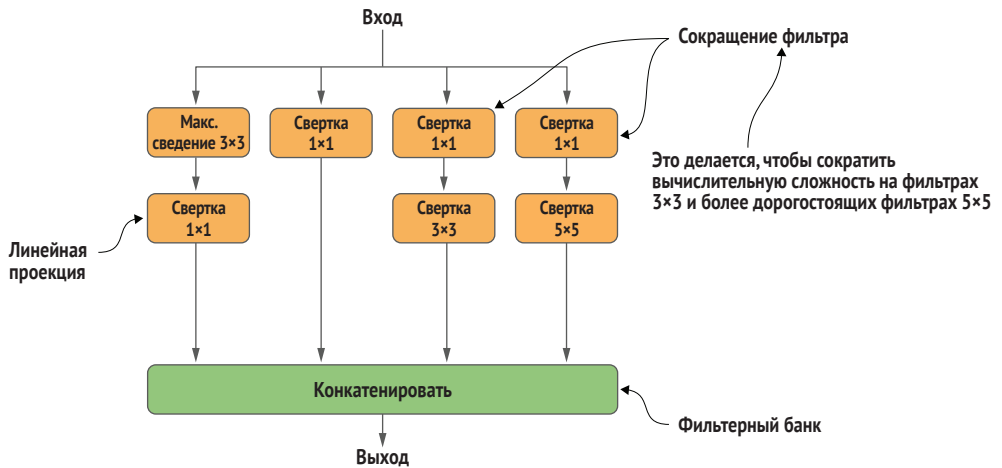


Рис. 6.2 Конструкция блока (модуля) Inception v1, который использовался в заявке ILSVRC 2014 года

Сводная информация (`summary()`) для этих слоев показывает 198 000 тренируемых параметров, в отличие от 544 000 параметров в нативном модуле Inception с использованием бутылочной свертки для редукции размерности. Разработчики модели смогли сохранить тот же уровень точности, что и в нативном модуле Inception, но с более быстрой тренировкой и улучшенной производительностью в предсказании (предсказательном выводе):

max_pooling2d_1 (MaxPooling2D)	(None, 28, 28, 256)	0	input_1[0][0]
conv2d_1 (Conv2D)	(None, 28, 28, 64)	16448	input_1[0][0]
conv2d_2 (Conv2D)	(None, 28, 28, 64)	16448	input_1[0][0]
conv2d_3 (Conv2D)	(None, 28, 28, 64)	16448	max_pooling2d_1[0][0]

conv2d_4 (Conv2D)	(None, 28, 28, 64)	16448	input_1[0][0]
conv2d_5 (Conv2D)	(None, 28, 28, 96)	55392	conv2d_4[0][0]
conv2d_6 (Conv2D)	(None, 28, 28, 48)	76848	conv2d_2[0][0]
concatenate_430 (Concatenate)	(None, 28, 28, 272)	0	conv2d_3[0][0] conv2d_1[0][0] conv2d_5[0][0] conv2d_6[0][0]
=====			
Total params: 198,032			
Trainable params: 198,032			

Как видно по рис. 6.3, архитектура Inception v1 после переоборудования в шаблон процедурного конструирования состоит из четырех компонентов: стержня, ученика, классификатора и вспомогательного классификатора. В целом макроархитектура, представленная шаблоном процедурного конструирования, является такой же, как и в предыдущих передовых моделях, которые я показывал, за исключением добавления вспомогательных классификаторов. Как показано на диаграмме, ученический компонент состоит из пяти сверточных групп, и каждая группа имеет разное число сверточных блоков. Вторая и четвертая сверточные группы являются единственными группами с одним сверточным блоком и группами, соединенными со вспомогательным классификатором.

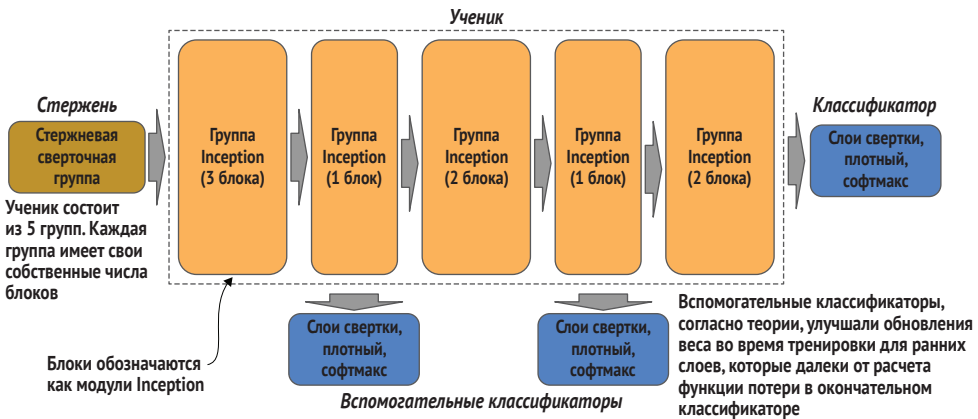


Рис. 6.3 В макроархитектуре Inception v1 после второй и четвертой групп Inception были добавлены вспомогательные классификаторы.

Тот факт, что Inception v1 занял первое место в конкурсе ILSVRC 2014 года на обнаружение признаков, продемонстрировал полезность разведывательного анализа шаблонов конструирования для широких слоев в соединении с более глубокими слоями.

Обратите внимание, что я ссылался на модули как на блоки, то есть пользовался термином, используемым в данном шаблоне конструирования. Далее мы рассмотрим каждый компонент подробнее.

6.1.3 Стержень

Стержень – это точка входа в нейронную сеть. Входные данные (изображения) обрабатываются последовательным (глубоким) набором сверток и максимальным сведением, во многом как в традиционной сети ConvNet.

Давайте немного углубимся в стержень, чтобы увидеть, чем его конструкция отличалась от традиционных передовых стержней того времени (рис. 6.4). В архитектуре Inception использовался очень грубый первоначальный фильтр 7×7 , за которым следовало очень агрессивное сокращение карт признаков, состоящее из двух пошаговых сверток и двух максимальных сведений. С другой стороны, он поступательно увеличивал число карт признаков с 64 до 192. Модель Inception кодировалась без выгоды от возможности перемещения фильтра за край в сверточном слое. Поэтому для того, чтобы сохранить сокращение высоты и ширины вдвое во время редукции, было добавлено дополнение нулями.




Рис. 6.4. Стержень Inception v1 состоит из грубого фильтра 7×7 , за которым следует детализированный фильтр 3×3 , а также редукции размерности после каждой свертки с максимальным сведением

6.1.4 Ученик

Ученик представляет собой набор из девяти блоков Inception в пяти группах, показанных ранее на рис. 6.3 и снова на рис. 6.5. Более широкие группы на диаграмме являются группой из двух или трех блоков Inception, а более тонкие являются одним одиночным блоком, в общей сложности девять блоков Inception. Четвертый и седьмой блоки (одиночные блоки) выделены отдельно, чтобы подчеркнуть,

что у них есть дополнительный компонент, вспомогательный классификатор.

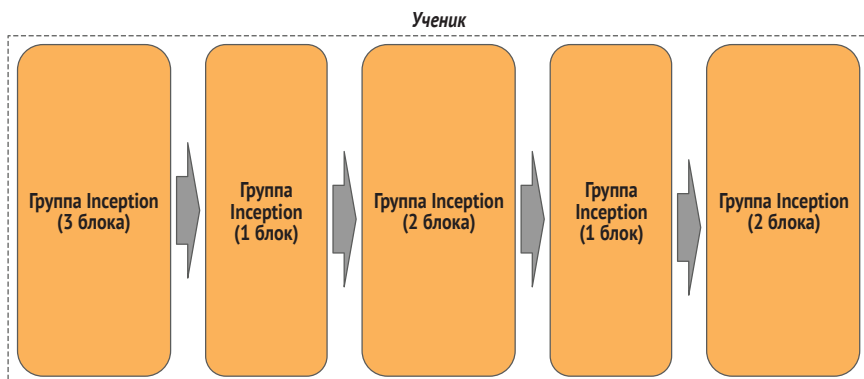


Рис. 6.5 Групповая конфигурация и число блоков в ученическом компоненте Inception v1

6.1.5 Вспомогательные классификаторы

Вспомогательные классификаторы представляют собой набор из двух классификаторов, действующих как вспомогательные компоненты (средства) при тренировке нейронной сети. Каждый вспомогательный классификатор состоит из сверточного слоя, плотного слоя и финальной активационной функции softmax (рис. 6.6). Софтмакс (как вы, возможно, уже знаете) – это уравнение из статистики, которое на входе принимает набор независимых вероятностей (от 0 до 1) и сжимает этот набор так, чтобы все вероятности в сумме составляли 1. В окончательном плотном слое с одним узлом в расчете на класс каждый узел делает независимое предсказание (от 0 до 1), и в результате пропускания этих значений через функцию софтмакс сумма предсказанных вероятностей для всех классов будет составлять 1.

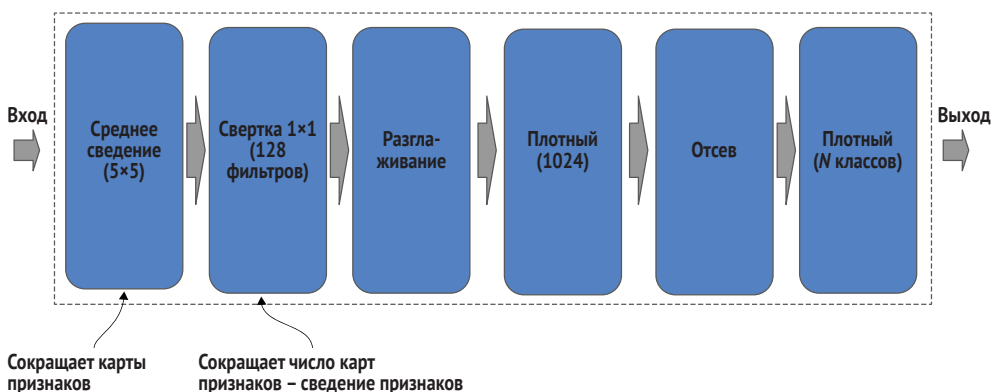


Рис. 6.6 Группа вспомогательных классификаторов Inception v1/v2

В архитектуре Inception v1 была введена концепция вспомогательного классификатора. Здесь принцип заключается в том, что по мере того, как нейронная сеть становится глубже в слоях (по мере того как передние слои дистанцируются от окончательного классификатора), передние слои в большей степени подвержены исчезающему градиенту и увеличению времени (увеличению числа эпох) для тренировки весов в самых первых слоях. Рисунок 6.7 иллюстрирует этот процесс. Обновления по мере распространения обновлений весов со стороны задних слоев, как правило, становятся все меньше.



Рис. 6.7 Обновления весов поступательно уменьшаются

Согласно авторам Inception v1, в теории это может привести к двум проблемам, которые они хотели исправить. Во-первых, если обновления становятся слишком малыми, то операция умножения может привести к тому, что число будет слишком малым, чтобы его представлять с плавающей точкой на компьютерном оборудовании (это называется *исчезающим градиентом*).

Другая проблема заключается в том, что если обновления ранних слоев намного меньше, чем более поздних, то для их схождения потребуется больше времени, что увеличит время тренировки. Кроме того, если более поздние слои сходятся рано, а ранние слои сходятся позже, то более поздние слои могут начать запоминать данные, тогда как ранние слои все еще будут учиться обобщать.

Теория авторов Inception v1 заключается в том, что в полуглубоких слоях есть некоторая информация для предсказания или классифицирования входных данных, хотя и с меньшей точностью, чем у окончательного классификатора. Эти более ранние классификаторы находятся ближе к передним слоям и, следовательно, подвержены исчезающему градиенту в меньшей степени. Во время тренировки стоимостная функция становится комбинацией потерь вспомогательных классификаторов и окончательного классификатора. Дру-

гими словами, авторы полагали, что комбинирование потерь вспомогательных и окончательного классификатора приведет к более равномерным обновлениям весов во всех слоях, облегчению проблемы исчезающего градиента и сокращению времени тренировки.

Вспомогательный классификатор, изображенный на рис. 6.6, используется как в модели Inception v1, так и в модели Inception v2. После Inception практика использования вспомогательного классификатора не применялась по двум причинам. Во-первых, по мере того как модели углублялись в слои, проблема исчезающих (и взрывающихся) градиентов стала более выраженной в более глубоких слоях, чем в передних слоях, поэтому теория не срабатывала в более глубоких нейронных сетях. Во-вторых, введение в 2015 году пакетной нормализации решало эту проблему единообразно во всех слоях.

По сравнению с конструкцией VGG, в Inception v1 исключено внесение дополнительных плотных слоев в классификатор (как во вспомогательный, так и в окончательный), в отличие от VGG, в которой было два дополнительных плотных слоя по 4096 узлов. Авторы предположили, что для того, чтобы натренировать окончательный плотный слой для проведения классифицирования, дополнительные плотные узлы не нужны. Это существенно снизило вычислительную сложность без снижения точности классификатора. В последующих передовых моделях исследователи обнаружили, что они могут без снижения точности устранить все предыдущие плотные слои между бутылочным и окончательным классификаторным слоями.

Модель Inception была одной из последних передовых моделей, в которой с целью уменьшения перепогонки в классификаторах для регуляризации использовался слой отсева. После последующего введения пакетной нормализации исследователи заметили, что нормализация добавляла небольшой объем регуляризации на послойной основе и давала более высокую эффективность при обобщении, чем отсев. В итоге исследователи ввели явную послойную регуляризацию, именуемую *весовой регуляризацией*, что еще больше улучшило регуляризацию. Таким образом, впоследствии использование отсева было постепенно свернуто.

6.1.6 Классификатор

На рис. 6.8 показан окончательный (не вспомогательный) классификатор как в тренировке нейронной сети, так и в предсказании. Обратите внимание, что в случае предсказания вспомогательные классификаторы удаляются. Классификатор имплементирует шаг глобального среднего сведения в виде двух слоев; первый слой (AveragePooling2D) выполняет среднее сведение каждой карты признаков в карты признаков 1×1 , за которым затем следует слой разглаживания для разглаживания в 1-мерный вектор. Перед плотным (Dense) слоем для классификации использовался слой отсева (Dropout) для регуляризации, что было обычной практикой того времени.

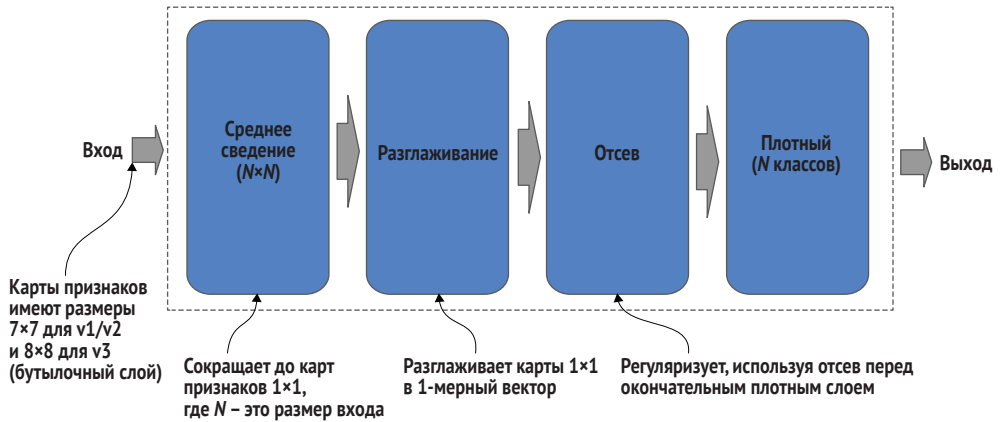


Рис. 6.8 В окончательном классификаторе Inception сведение в карты размером 1×1 пикселей и разглаживание выполняются в два шага

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для Inception v1 находится в репозитории на GitHub (<http://mng.bz/oGnd>).

Далее давайте посмотрим на то, как архитектура Inception v2 ввела концепцию разложения вычислительно дорогостоящих сверток.

6.2 Inception v2: разложение сверток

Чем больше размер фильтра (ядра) в свертке, тем дороже он обходится в вычислительном отношении. В документе, в котором была представлена архитектура Inception v2, было подсчитано, что свертка 5×5 в модуле Inception стоит в 2.78 раза дороже в вычислительном отношении, чем свертка 3×3 . Другими словами, фильтр 5×5 требует почти в три раза больше операций `matmul`, требуя больше времени для тренировки и предсказания. Цель авторов состояла в том, чтобы найти способ заменить фильтры 5×5 фильтром 3×3 , дабы сократить время тренировки/предсказания без ущерба для точности модели.

Модель Inception v2 ввела *разложение* в отношении более дорогостоящих сверток в модуле Inception, чтобы сократить вычислительную сложность и уменьшить потерю информации из представительных бутылочных горлышек. На рис. 6.9 показана потеря представления. На этом изображении мы показываем фильтр 5×5 , который охватывает область в 25 пикселей. Во время каждого шага скольжения фильтра область в 25 пикселей заменяется (представляется) одним пикселем. Этот один пиксел в соответствующей карте признаков в последующей операции сведения будет сокращен вдвое. Потеря представления – это коэффициент сжатия, в данном случае 50 (25 к 0.5). Для меньшего фильтра 3×3 потеря представления составляет 18 (9 к 0.5).

В модуле Inception v2 фильтр 5×5 заменяется стопкой из двух фильтров 3×3 , что приводит к сокращению вычислительной сложности замененного фильтра 5×5 на 33 %.

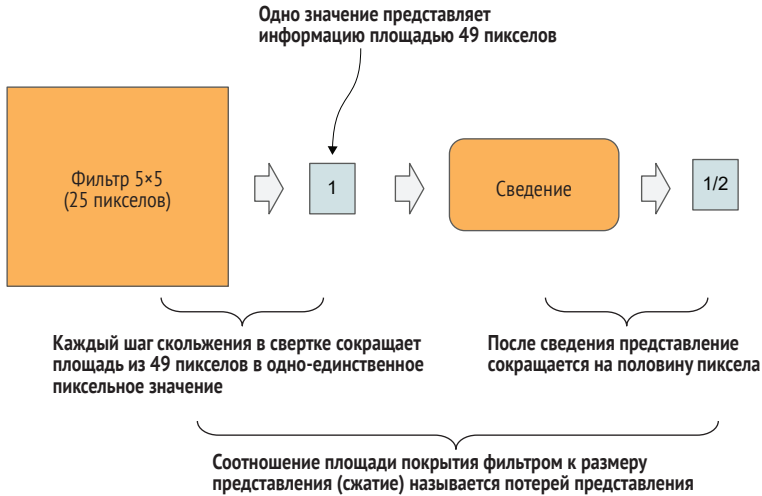


Рис. 6.9 Потеря представления между фильтром и выдаваемым пиксельным значением после последующего сведения

В дополнение к этому потеря в представительном бутылочном горлышке возникает при наличии больших различий в размерах фильтров. Благодаря замене фильтра 5×5 двумя фильтрами 3×3 все небутылочные фильтры теперь имеют одинаковый размер, а совокупная точность архитектуры Inception v2 увеличивается по сравнению с архитектурой Inception v1.

Рисунок 6.10 иллюстрирует блок Inception v2: свертка 5×5 в v1 заменяется двумя свертками 3×3 .

Модель Inception v2 также добавила использование постактивационной пакетной нормализации (Conv-BN-ReLU) для каждого сверточного слоя. Поскольку пакетная нормализация не была введена до 2015 года, в версии v1 2014 года не было выгод от использования этого метода. На рис. 6.11 показана разница между предыдущей сверткой без пакетной нормализации (Conv-ReLU) и постактивационной пакетной нормализацией.

Ниже приведен пример исходного кода модуля Inception v2, который отличается от версии v1 следующим образом:

- за каждым сверточным слоем следует пакетная нормализация;
- свертка 5×5 версии v1 заменена двумя свертками 3×3 , а разложение более дорогостоящей 5×5 на менее дорогостоящую пару сверток 3×3 сократило вычислительную сложность и потерю информации из представительных бутылочных горлышек.

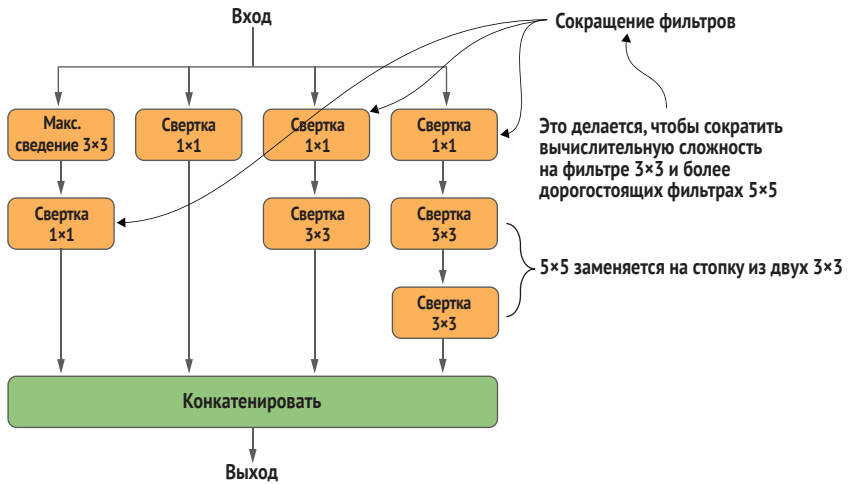


Рис. 6.10 В блоке Inception v2 свертка 5×5 заменена более эффективной стопкой из двух сверток 3×3

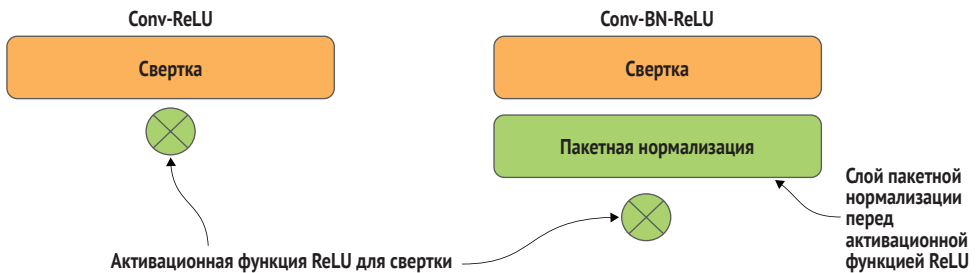


Рис. 6.11 Сравнение сверточного слоя и активации до и после традиционного правила добавления пакетной нормализации

Использует постактивационную пакетную нормализацию

```

x1 = MaxPooling2D((3, 3), strides=(1,1), padding='same')(x)
x1 = Conv2D(64, (1, 1), strides=(1, 1), padding='same')(x1)
x1 = BatchNormalization()(x1)
x1 = ReLU()(x1)

x2 = Conv2D(64, (1, 1), strides=(1, 1), padding='same')(x)
x2 = BatchNormalization()(x2)
x2 = ReLU()(x2)

x3 = Conv2D(64, (1, 1), strides=(1, 1), padding='same')(x)
x3 = BatchNormalization()(x3)
x3 = ReLU()(x3)
x3 = Conv2D(96, (3, 3), strides=(1, 1), padding='same')(x3)
x3 = BatchNormalization()(x3)
x3 = ReLU()(x3)

x4 = Conv2D(64, (1, 1), strides=(1, 1), padding='same')(x)

```

Inception
ветвится там,
где x является
предыдущим
слоем

```

x4 = BatchNormalization()(x4)
x4 = ReLU()(x4)
x4 = Conv2D(48, (3, 3), strides=(1, 1), padding='same')(x4)
x4 = BatchNormalization()(x4)
x4 = ReLU()(x4)
x4 = Conv2D(48, (3, 3), strides=(1, 1), padding='same')(x4)
x4 = BatchNormalization()(x4)
x4 = ReLU()(x4)

x = Concatenate([x1, x2, x3, x4]) ← Конкатенирует карты признаков из ветвей

```

Сводная информация (`summary()`) для этих слоев показывает 169 000 тренируемых параметров по сравнению с 198 000 для модуля Inception v1.

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для Inception v2 находится в репозитории на GitHub (<http://mng.bz/oGnd>). Далее мы опишем особенности модернизации архитектуры Inception в версии 3.

6.3 Inception v3: модернизация архитектуры

В версии *Inception v3* была представлена новая конструкция макроархитектуры, а также модернизирована стержневая группа и использован только один вспомогательный классификатор. Кристиан Сегеди и соавт. сослались на эту компоновку в названии своей статьи «Переосмысление архитектуры Inception» (Christian Szegedy et al., Rethinking the Inception Architecture, <https://arxiv.org/abs/1512.00567>).

Авторы отметили, что в последние годы были достигнуты существенные успехи в повышении точности и сокращении размера параметров за счет углубления и расширения. У AlexNet было 60 млн параметров, а у VGG их было в три раза больше, тогда как у Inception v1 было всего 5 млн. Авторы подчеркнули необходимость создания эффективных архитектур, которые могли бы переместить модели в реальные условия, и обеспечения дальнейшей эффективности в параметрах при одновременном повышении точности.

По их мнению, архитектура Inception v1/v2 для этой цели была слишком сложной. Например, удвоение размера фильтрных банков в целях увеличения емкости увеличивало число параметров в четыре раза. Мотивацией для модернизации было упрощение архитектуры при сохранении вычислительных преимуществ при масштабировании и повышении точности существующих передовых моделей того времени.

В ходе модернизации сверточные блоки были разложены, чтобы иметь возможность эффективно масштабировать архитектуру. На рис. 6.12 показана макроархитектура: учебный компонент состоит из трех групп (А, В и С) для усвоения признаков, а также двух

группы редукции решетки для сокращения карты признаков. Кроме того, число вспомогательных классификаторов сокращено с двух до одного.

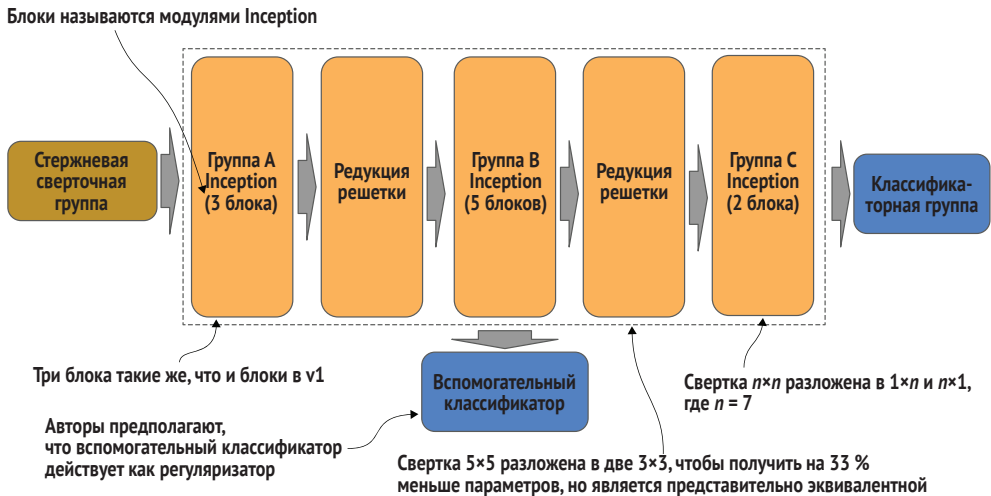


Рис. 6.12 Модернизированная макроархитектура Inception v3 упростила архитектуру Inception v1 и v2

Давайте посвятим следующие несколько разделов более пристальному рассмотрению этих модернизированных компонентов.

6.3.1 Группы и блоки архитектуры Inception

В основу модернизации архитектуры Inception легли четыре конструктивных принципа:

- 1 избегать потери представления;
- 2 многомерные представления легче обрабатывать локально внутри сети;
- 3 более высокоразмерная пространственная агрегация может выполняться над более низкоразмерными вложениями без особой потери в представительной мощности;
- 4 балансировать ширину и глубину сети.

Микроархитектура Inception отражала первый конструктивный принцип, заключающийся в сокращении потери информации из представительных бутылочных горлышек, путем достижения более постепенного сокращения размера карт признаков. В ней также рассматривался принцип 4, уравнивающий ширину и глубину сверточных слоев. Авторы отметили, что оптимальное улучшение произошло, когда увеличение ширины и глубины выполнялось в параллельном режиме, а вычислительный бюджет сбалансирован между ними. Следовательно, модель увеличивает и ширину, и глубину, чтобы способствовать получению более высококачественных сетей.

Теперь давайте увеличим масштаб еще больше и посмотрим на модернизацию групп А, В и С. Блоки в группе А остаются такими же, как и в более ранних версиях, тогда как группы В и С отличаются. Размеры выходных карт признаков для групп А, В и С составляют соответственно 35×35 , 17×17 и 8×8 . Обратите внимание на постепенное сокращение размеров карт признаков, так как каждая группа сокращается вдвое $H \times W$. Это постепенное сокращение по трем группам отражает конструктивный принцип 1, сокращение потери в представлении по мере углубления сети.

На рис. 6.13 и 6.14 показаны блоки соответственно в группах В и С. В этих двух группах некоторые из $N \times N$ сверток разлагаются на пространственно разделяемые свертки $N \times 1$ и $1 \times N$. Эта корректировка отражает конструктивный принцип 3, который гласит, что пространственно разделяемые свертки, выполняемые на меньшей размерности карт признаков, не теряют представительной мощности.

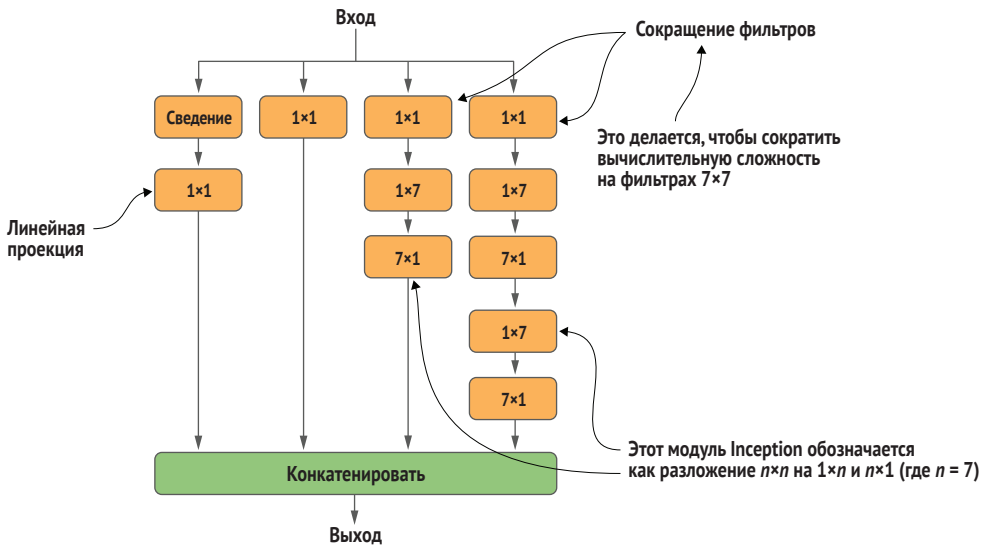


Рис. 6.13. Блок Inception v3 17×17 (группа В) с использованием пространственно разделяемой свертки

В более ранних версиях Inception карты признаков между сверточными группами сводились для того, чтобы редуцировать размерность, и удваивались по числу, что, по мнению исследователей, было причиной потери представления (конструктивный принцип 1). Вместо того они предложили выполнять стадии сокращения карт признаков между группами с помощью параллельных сверток и сведения, как показано на рис. 6.15. Однако после Inception v3 этот подход для устранения потери представления во время редукции в дальнейшем не применялся.

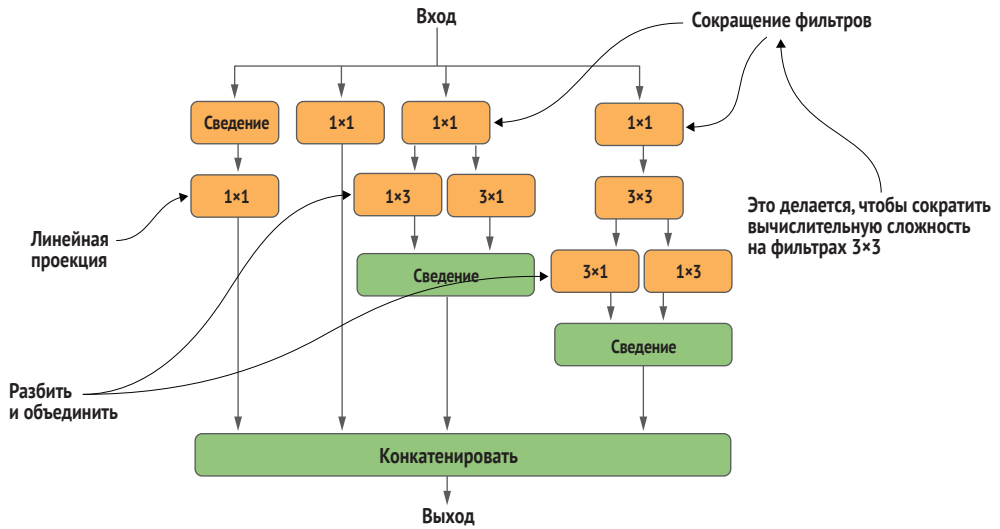


Рис. 6.14 Блок Inception v3 8×8 (группа C) с использованием параллельной пространственно разделяемой свертки

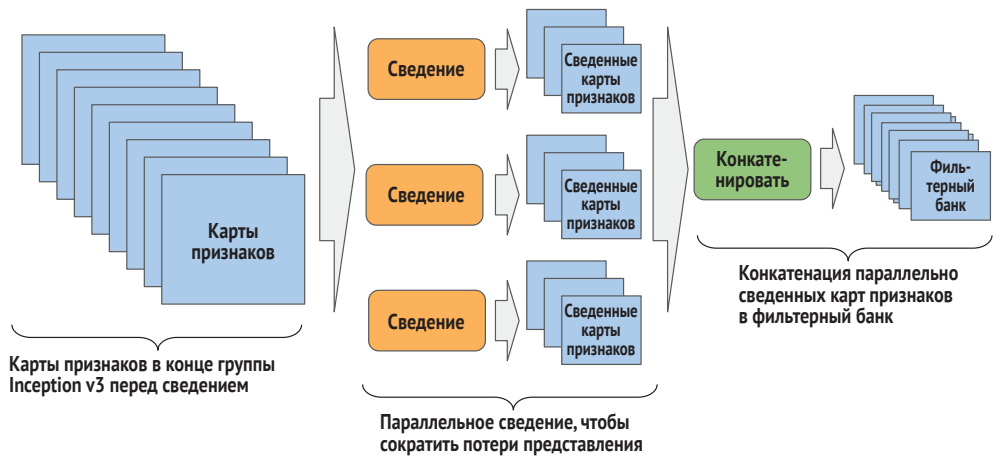


Рис. 6.15 Использование параллельного сведения карт признаков для сокращения потери представления

Параллельное сведение после групп А и В показано соответственно на рис. 6.16 и 6.17. Эти блоки сведения, именуемые *редукцией решетки*, сокращают число карт признаков (или каналов) из выходных данных предыдущей группы, чтобы совпадать с входными данными следующей группы. Таким образом, блок А редукции решетки сокращается с 35×35 до 17×17 , а блок В редукции решетки сокращается с 17×17 до 8×8 (удовлетворяя конструктивному принципу 1).

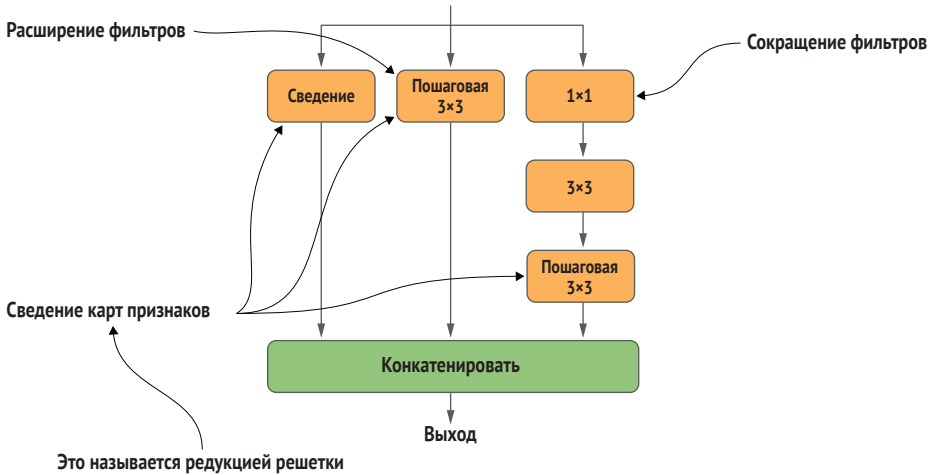


Рис. 6.16 Блок Inception v3 17×17 редукции решетки (группа А)

Вдобавок, отражая конструктивный принцип 3, свертка 7×7 , наряду с некоторыми свертками 3×3 в группах В и С, и редукция решетки в группе В заменяются пространственной сверткой соответственно $(7 \times 1, 1 \times 7)$ и $(3 \times 1, 1 \times 3)$.

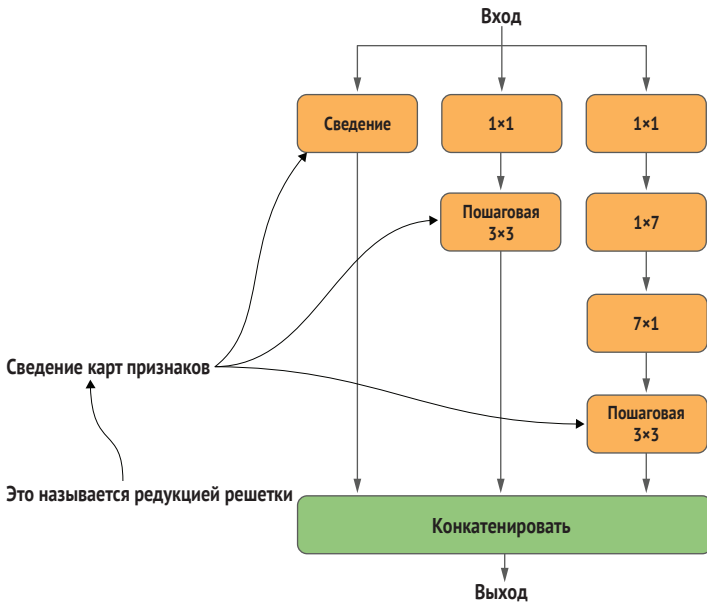


Рис. 6.17 Блок Inception v3 8×8 редукции решетки (группа В)

Теперь давайте сравним нормальную свертку из Inception v1 и v2, которую мы называем просто нормальной сверткой, с пространственно разделяемой сверткой из v3.

6.3.2 Нормальная свертка

В *нормальной свертке* ядро (например, 3×3) применяется по каналам высоты (H), ширины (W) и глубины (D). Всякий раз, когда ядро перемещается, число операций матричного умножения равно числу пикселей в виде $H \times W \times D$.

Например, изображение RGB (имеющее три канала) с ядром 3×3 , применяемым ко всем трем каналам, использует $3 \times 3 \times 3 = 27$ операций матричного умножения (matmul), создавая карту признаков $N \times M \times 1$ (например, $8 \times 8 \times 1$) (в расчете на ядро), где N и M – это результирующая высота и ширина карты признаков; см. рис. 6.18.

Ядро размером 3×3 перемещается по каждому каналу (например, $3 \times 3 \times 3$) изображения размером $H \times W$




Рис. 6.18 Дополненная свертка с одним фильтром

Если задать 256 фильтров для вывода свертки, то у нас будет 256 тренируемых ядер. В примере RGB с использованием 256 ядер 3×3 это означает 6912 операций матричного умножения при каждом перемещении ядер; см. рис. 6.19. Таким образом, даже при малом размере ядра 3×3 нормальные свертки становятся вычислительно дорогостоящими, поскольку мы увеличиваем число выходных карт признаков для большей представительной мощности.

X (например, 256) ядер 3×3 перемещаются по каждому каналу (например, $3 \times 3 \times 256$)




Рис. 6.19 Дополненная свертка с несколькими фильтрами

6.3.3 Пространственно разделяемая свертка

С другой стороны, *пространственно разделяемая свертка* разлагает 2-мерное ядро (например, 3×3) на два меньших 1-мерных ядра. Если представить 2-мерное ядро как $H \times W$, то разложенные два меньших 1-мерных ядра будут иметь размеры $H \times 1$ и $1 \times W$. Указанное разложение уменьшает суммарное число вычислений на одну треть. Хотя это разложение не всегда сохраняет эквивалентность представления, исследователи продемонстрировали, что они смогли поддерживать эквивалентность представления в Inception v3. На рис. 6.20 нормальная свертка сравнивается с разделяемой сверткой.

В примере RGB с ядром 3×3 нормальная свертка будет составлять $3 \times 3 \times 3$ (каналы) = 27 операций матричного умножения при каждом перемещении ядра. В том же примере RGB с разложенным ядром 3×3 пространственно разделяемая свертка будет составлять $(3 \times 1 \times 3) + (1 \times 3 \times 3) = 18$ операций матричного умножения при каждом перемещении ядра. Таким образом, число операций матричного умножения сокращается на треть ($18/27$).

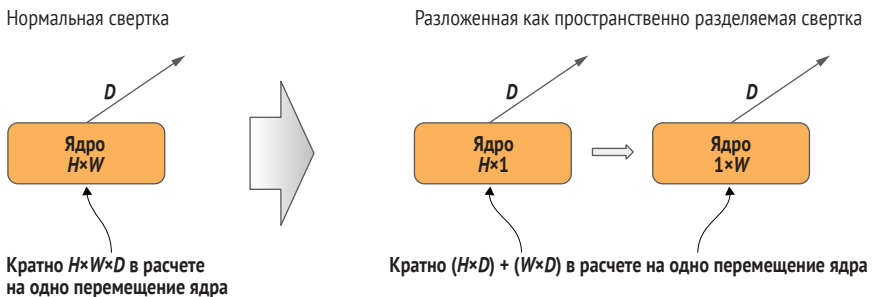


Рис. 6.20 Нормальная и пространственно разделяемая свертка

В примере RGB с использованием 256 ядер 3×3 мы выполняем 4608 операций матричного умножения при каждом перемещении ядер, в отличие от нормальной свертки, в которой было бы 6912 операций матричного умножения.

6.3.4 Модернизация и имплементация стержня

К моменту разработки Inception v3 на практике было принято заменять грубые фильтры 5×5 стопкой из двух фильтров 3×3 , что меньше в вычислительном отношении (18 против 25 матричных операций *matmul*) и удерживает представительную мощность. Используя тот же принцип, авторы предположили, что грубоуровневая свертка 7×7 , которая обходится дорого в вычислительном отношении (49 операций *matmul* в расчете на перемещение), может быть заменена стопкой из трех сверток 3×3 (27 операций *matmul* в расчете на перемеще-

ние). За счет этого было сокращено число параметров в стержневом компоненте, при этом удержана представительная мощность.

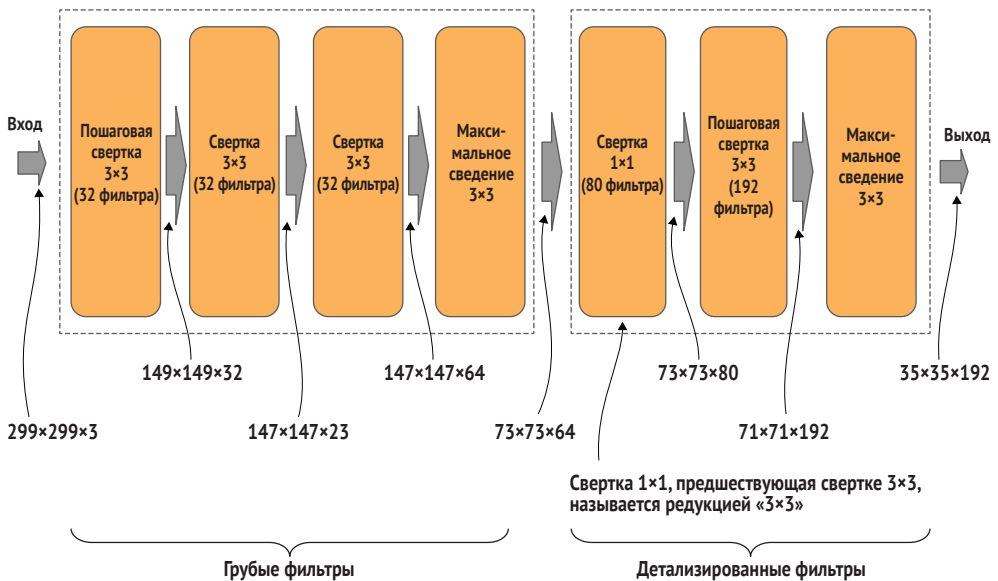


Рис. 6.21 Группа Inception v3, состоящая из стопки в размере трех сверток 3×3 , заменяющих свертку 7×7 в v1/v2

На рис. 6.21 показано, как свертка 7×7 в стержневой сверточной группе была разложена и заменена стопкой из трех сверток 3×3 следующим образом:

- 1 первые 3×3 являются пошаговой сверткой (strides=2, 2), которая выполняет сокращение карт признаков;
- 2 вторая 3×3 является нормальной сверткой;
- 3 третья 3×3 удваивает число фильтров.

Модель Inception v3 стала одной из последних передовых моделей, основанных на разложенном (или неразложенном) грубом фильтре 7×7 . Сегодня на практике принято использовать разложенный (или неразложенный) фильтр 5×5 . И следующий ниже пример исходного кода является имплементацией стержневой группы Inception v3, состав которой таков:

- 1 стопка из трех сверток 3×3 (разложенных на 7×7), в которой первая свертка выполняется пошагово для сведения признаков (размер 25 % от входной формы);
- 2 слой максимального сведения для дальнейшей редукции размерности карт признаков (6 % размера входной фигуры);
- 3 линейно-проекционная свертка 1×1 для расширения числа карт признаков с 64 до 80;
- 4 свертка 3×3 для дальнейшего расширения размерности до 192 карт признаков;

- 5 второй слой максимального сведения для дальнейшей редукции размерности карт признаков (1.5 % размера входной формы).

```

x = Conv2D(32, (3, 3), strides=(2, 2), padding='same')(input)
x = BatchNormalization()(x)
x = ReLU()(x)
x = Conv2D(32, (3, 3), strides=(1, 1), padding='same')(x)
x = BatchNormalization()(x)
x = ReLU()(x)
x = Conv2D(64, (3, 3), strides=(1, 1), padding='same')(x)
x = BatchNormalization()(x)
x = ReLU()(x)

# слой максимального сведения
x = MaxPooling2D((3, 3), strides=(2, 2), padding='same')(x)
x = Conv2D(80, (1, 1), strides=(1, 1), padding='same')(x)
x = BatchNormalization()(x)
x = ReLU()(x)
x = Conv2D(192, (3, 3), strides=(1, 1), padding='same')(x)
x = BatchNormalization()(x)
x = ReLU()(x)
x = MaxPooling2D((3, 3), strides=(2, 2), padding='same')(x)

```

Стержень Inception v3, 7×7 заменяется стопкой из сверток 3×3

Линейно-проекционная свертка 1×1

Расширение карты признаков (расширение размерности)

Сведение карт признаков (редукция размерности)

Сводная информация (`summary()`) для стержневой группы показывает 614 000 тренируемых параметров с входом (229, 229, 3).

6.3.5 Вспомогательный классификатор

Еще одно изменение в модели Inception v3 состояло в том, чтобы свести два вспомогательных классификатора к одному вспомогательному и еще больше его упростить, как показано на рис. 6.22. Авторы объяснили, что они внесли эти изменения, потому что «обнаружили, что вспомогательные классификаторы не приводят к улучшению схождения на ранней стадии тренировки». Оставив один классификатор, похоже, что они нацелились на золотую середину.

И точно так же они приняли традиционное правило того времени удалять дополнительные плотные слои перед окончательным классификатором, еще больше снижая число параметров. Более ранние исследователи установили, что удаление дополнительных плотных слоев (перед плотным классификационным слоем) не приводило к потере точности.

Вспомогательный классификатор был упрощен еще больше до следующего:

- слой среднего сведения (`AveragePooling2D`), который сводит каждую карту признаков к одной матрице 1×1;
- слой свертки 3×3 (`Conv2D`), который выводит 768 карт признаков 1×1;

- разглаживающий слой для разглаживания (Flatten) карт признаков в 1-мерный вектор из 768 элементов;
- окончательный плотный (Dense) слой для классифицирования.

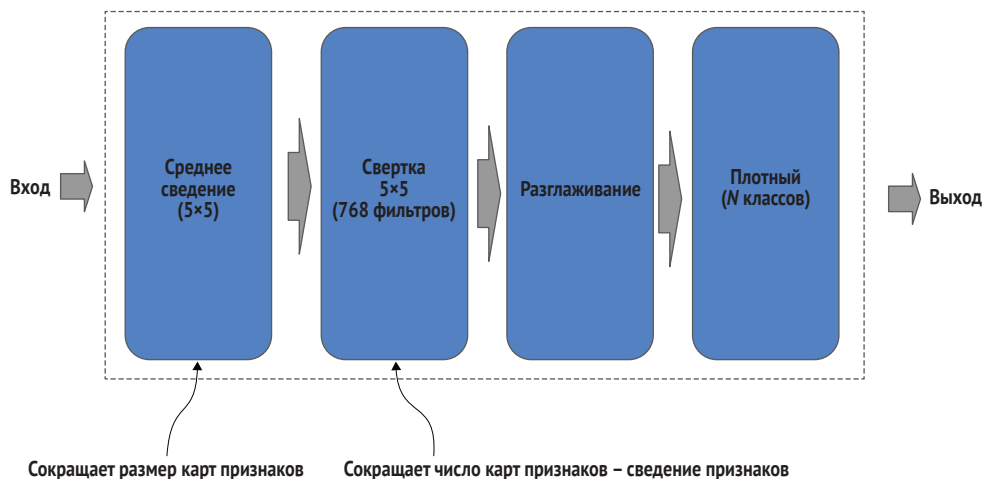


Рис. 6.22 Вспомогательная группа модели Inception v3

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для Inception v3 находится в репозитории на GitHub (<http://mng.bz/oGnd>).

6.4 ResNeXt: широкие остаточные нейронные сети

Архитектура ResNeXt от Facebook AI Research, занявшая первое место в конкурсе ILSVRC 2016 года в обработке ImageNet, представила широкий остаточный блок, в котором используется шаблон разбивки-преобразования-слияния для параллельных сверток. Такая архитектура для параллельных сверток называется *групповой сверткой*.

Число параллельных сверток составляет ширину и называется *кардинальностью*. Например, в конкурсе 2016 года в архитектуре ResNeXt использовалась кардинальность 32, то есть каждый слой ResNeXt состоял из 32 параллельных сверток.

Здесь идея заключалась в том, что добавление параллельных сверток будет помогать повышать модельную точность без необходимости уходить вглубь, что более подвержено забыванию. В своем абляционном исследовании (<https://arxiv.org/abs/1611.05431>) Сайнинг Се и соавт. сравнили ResNeXt с 50, 101 и 200 слоями ResNet и 101 и 200 слоями Inception v3 в наборе данных ImageNet. Во всех случаях

архитектура ResNeXt в одном и том же слое глубины обеспечивала более высокую точность.

Если посмотреть на репозитории преднатренированных моделей, такие как TensorFlow Hub, то можно увидеть, что вариант SE-ResNeXt имеет слегка более высокую вычислительную мощность и более высокую точность и предпочтителен в качестве магистрального направления классифицирования изображений.

6.4.1 Блок ResNeXt

В каждом слое ResNeXt входные данные из предыдущего слоя разбиваются по параллельным сверткам, а выходные данные (карты признаков) из каждой свертки конкатенируются обратно. Наконец, данные на входе в слой присоединяются путем матричного сложения к конкатенированному выходу (отождествляющая связь) для формирования остаточного блока. Этот набор слоев называется операцией *разбивки-преобразования-слияния и масштабирования*. Определение этих терминов поможет прояснить суть операции:

- *разбивка* относится к разбиению карт признаков на группы в зависимости от кардинальности;
- *преобразование* – это то, что происходит в параллельных свертках для каждой группы;
- *слияние* относится к операции конкатенации результирующих карт признаков;
- *масштабирование* обозначает операцию сложения в отождествляющей связи.

Целью операции разделения-преобразования-слияния было повышение точности без увеличения числа параметров. Она делала это путем конвертирования элементарного преобразования ($w \times h$) в агрегированное преобразование «сеть в нейроне».

Теперь что касается архитектуры, в которой указанные концепции имплементированы. Как видно по рис. 6.23, широкая группа остаточных блоков ResNeXt состоит из следующих элементов:

- первой бутылочной свертки (ядро 1×1);
- свертки разбивка-ветвление-конкатенация кардинальностью N (групповой свертки);
- окончательной бутылочной свертки (ядро 1×1);
- отождествляющей связи (аббревиатуры) между входом и окончательным выходом из свертки.

Давайте рассмотрим операцию разбивки-преобразования-слияния групповой свертки (рис. 6.24) подробнее. Вот как применяются три главенствующих шага.

- 1 Разбивка: входные данные (карты признаков) равно разбиваются на N групп (где N – это кардинальность).
- 2 Преобразование: каждая группа пропускается через отдельную свертку 3×3 .

- 3 Слияние: все преобразованные группы конкатенируются обратно.

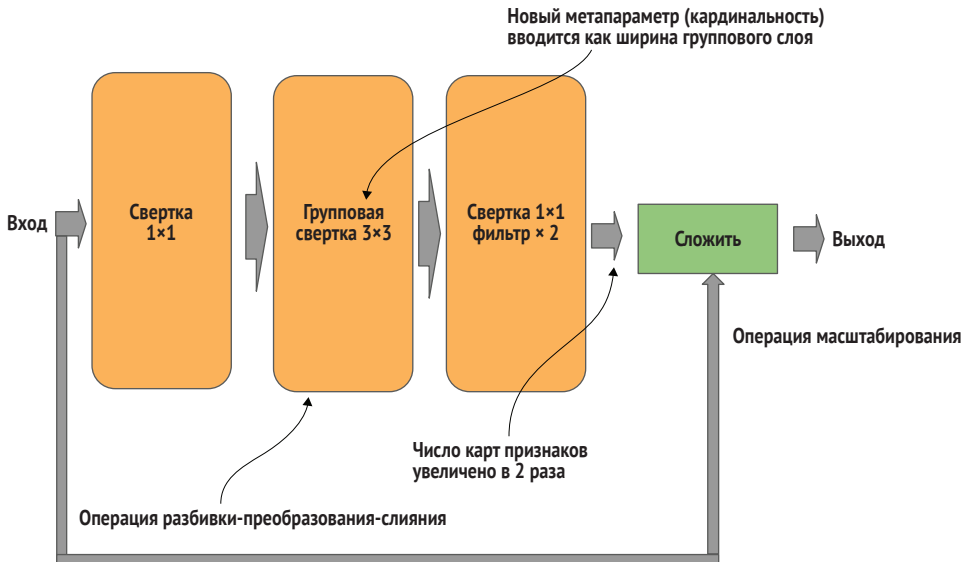


Рис. 6.23 Остаточный следующий блок (ResNeXt-блок) с отождествляющей аббревиатурой, в котором имплементированы операции разбивки-преобразования-слияния и масштабирования

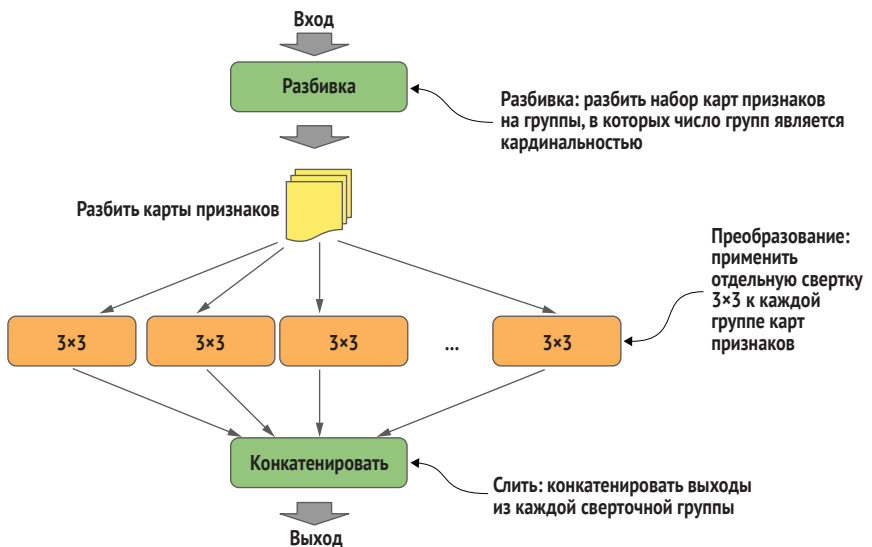


Рис. 6.24 Групповая свертка ResNeXt, имплементирующая операцию разбивки-преобразования-слияния

Первая бутылочная свертка выполняет редукцию размерности путем сокращения (сжатия) числа входных карт признаков. Мы

встречали аналогичное использование бутылочной свертки, когда рассматривали бутылочный остаточный блок в главе 5 и в модуле Inception в разделах 6.1–6.3.

После бутылочной свертки карты признаков разбиваются между параллельными свертками в соответствии с кардинальностью. Например, если число входных карт признаков (или каналов) равно 128, а кардинальность равна 32, то каждая параллельная свертка получит 4 карты признаков, что равно числу карт признаков, деленному на кардинальность, или 128, деленному на 32.

Данные на выходе из параллельных сверток затем конкатенируются обратно в полный набор карт признаков, которые потом пропускаются через окончательную бутылочную свертку для еще одной редукции размерности. Как и в остаточном блоке, между входом и выходом из блока ResNeXt имеется отождествляющая связь, а указанный блок затем подвергается операции матричного сложения.

Следующий ниже пример кодирования блока ResNeXt состоит из четырех кодовых последовательностей:

- 1 данные на входе в блок (аббревиатура) пропускаются через бутылочную свертку 1×1 , чтобы выполнить редукцию размерности;
- 2 операция разбивки-преобразования (групповая свертка);
- 3 операция слияния (конкатенация);
- 4 вход складывается (путем операции матричного сложения) с выходом из операции слияния (отождествляющая связь) в качестве операции масштабирования.

Вычисляет число каналов в расчете на группу
путем деления на размер (ширину) кардинальности

```
shortcut = x
```

```
x = Conv2D(filters_in, (1, 1), strides=(1, 1), padding='same')(shortcut)
```

```
x = BatchNormalization()(x)
```

```
x = ReLU()(x)
```

Аббревиатурная связь представляет собой
бутылочную свертку 1×1 для редукции
размерности

```
filters_card = filters_in // cardinality
```

```
groups = []
```

```
for i in range(cardinality):
```

```
    group = Lambda(lambda z: z[:, :, :, i * filters_card:i *  
                           filters_card + filters_card])(x)
```

```
    groups.append(Conv2D(filters_card, (3, 3), strides=(1, 1),  
                        padding='same')(group))
```

Выполняет шаг
слияния путем
конкатенирования
выходов из
групповых сверток

```
x = Concatenate()(groups)
```

```
x = BatchNormalization()(x)
```

```
x = ReLU()(x)
```

```
x = Conv2D(filters_out, (1, 1), strides=(1, 1), padding='same')(x)
```

```
x = BatchNormalization()(x)
```

Линейная проекция 1×1
для восстановления размерности

```
x = Add()([shortcut, x])
```

```
x = ReLU()(x)
```

```
return x
```

Складывает аббревиатуру с выходом из блока

Обратите внимание, что в этом листинге исходного кода метод `Lambda()` выполняет разбивку карт признаков. Последовательность `z[:, :, :, i * filters_card:i * filters_card + filters_card]` является скользящим окном, которое разбивает входные карты признаков по четвертой размерности; четвертыми размерностями являются каналы $B \times H \times W \times C$.

6.4.2 Архитектура ResNeXt

Архитектура, изображенная на рис. 6.25, начинается со стержневой сверточной группы для входа, состоящего из свертки 7×7 , который затем пропускается через слой максимального сведения с целью редукции данных.

За стержнем следуют четыре группы блоков ResNeXt. Каждая группа поступательно удваивает число выводимых фильтров по сравнению с входным. Между каждым блоком находится пошаговая свертка, которая служит двум целям:

- она сокращает данные на 75 % (сведение признаков);
- она удваивает фильтры на выходе из предыдущего слоя, поэтому когда устанавливается отождествляющая связь между входом в этот слой и выходом из него, то число фильтров совпадает для операции матричного сложения.

После окончательной группы ResNeXt выход передается классификаторному компоненту. Классификатор состоит из слоя максимального сведения и слоя разглаживания, который разглаживает входы в 1-мерный вектор, а затем передает их в один плотный слой для классифицирования.



Рис. 6.25 Ученический компонент ResNeXt, показывающий сведение признаков между сверточными группами

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для ResNeXt находится в репозитории на GitHub (<http://mng.bz/my6r>).

6.5 Широкая остаточная сеть

В широкой остаточной сети (wide residual network, аббр. WRN), представленной в 2016 году исследователями из ParisTech, использовался еще один подход к широким сверточным нейронным сетям. Исследователи исходили из теории, что по мере углубления модели в слои реиспользование признаков сокращается, и поэтому тренировка занимает все больше времени. Они провели исследование с использованием остаточных сетей и добавили параметр для множителя числа фильтров (ширины) в расчете на остаточный блок. За счет него была уменьшена глубина. Когда они протестировали эту конструкцию, то обнаружили, что WRN всего с 16 слоями может превосходить по результативности другие передовые архитектуры.

Вскоре конструкция под названием DenseNet продемонстрирует еще одну альтернативу для решения проблемы реиспользования признаков в более глубоких слоях. Как и в случае с WRN, авторы архитектуры DenseNet исходили из допущения, что увеличение реиспользования признаков приводит к большей представительной мощности и повышению точности. Архитектура DenseNet, однако, добилась реиспользования с помощью концентрации карт признаков входных данных с выходом из каждого остаточного блока.

В абстрактном исследовании «Широкие остаточные сети» (Wide Residual Networks, Sergey Zagoruyko and Nikos Komodakis, <https://arxiv.org/pdf/1605.07146.pdf>) Сергей Загоруйко и Никос Комодакис применили свой принцип расширения к модели ResNet50, который они назвали WRN-50-2, и обнаружили, что он превосходит глубокую ResNet101 еще более. В современных передовых моделях с целью достижения более высокой производительности, более быстрой тренировки и меньшего запоминания принят принцип использования как широких, так и глубоких слоев.

6.5.1 Архитектура WRN-50-2

В данной модели WRN использовались следующие конструктивные соображения.

- 1 Использовать предактивационную пакетную нормализацию (BN-RE-Conv) для более быстрой тренировки, как в ResNet v2.
- 2 Использовать две свертки 3×3 (B(3, 3)), как в ResNet34, вместо менее представительного выразительного бутылочного остаточного блока (B(1,3,1)) в ResNet50. Логическое основание здесь зиждется на том факте, что бутылочная конструкция помогала сокращать параметры для повышения точности *по мере углубления сетей*. *Расширяясь* с целью повышения точности, сеть становится более мелкой и, следовательно, может владеть более представительным выразительным стеком.
- 3 Обозначать через l число сверточных слоев в группе и через k фактор ширины для умножения числа фильтров.

- 4 Перемещать операцию отсева с верхних слоев (что делалось по традиции) в места между каждым сверточным слоем в остаточных блоках и после ReLU. Причина здесь заключалась в пертурбировании пакетной нормализации.

В макроархитектуре на рис. 6.26 показаны три из этих принципов в действии, вследствие чего каждая сверточная группа удваивает число выходных признаков. В каждой свертке используется предактивационная пакетная нормализация (конструктивный принцип 1). Каждый остаточный блок в группе использует остаточный блок $B(3,3)$ (конструктивный принцип 2). И метепараметр k используется для множителя ширины на числе фильтров в расчете на свертку (конструктивный принцип 3). Не изображен отсев в остаточных блоках (конструктивный принцип 4).




Рис. 6.26 В макроархитектуре WRN каждая сверточная группа поступательно удваивает число выходных карт признаков

6.5.2 Широкий остаточный блок

Давайте сосредоточимся на широком остаточном блоке, который состоит из различных остаточных групп. На рис. 6.27 показано, что обе свертки 3×3 ($B(3,3)$) имеют число фильтров, умноженное на конфигурируемый фактор ширины (k). Между сверткой 3×3 находится слой отсева для блочно-уровневой регуляризации. В остальном конструкция широкого остаточного блока идентична остаточному блоку ResNet34.

А вот пример кодирования широкого остаточного блока:



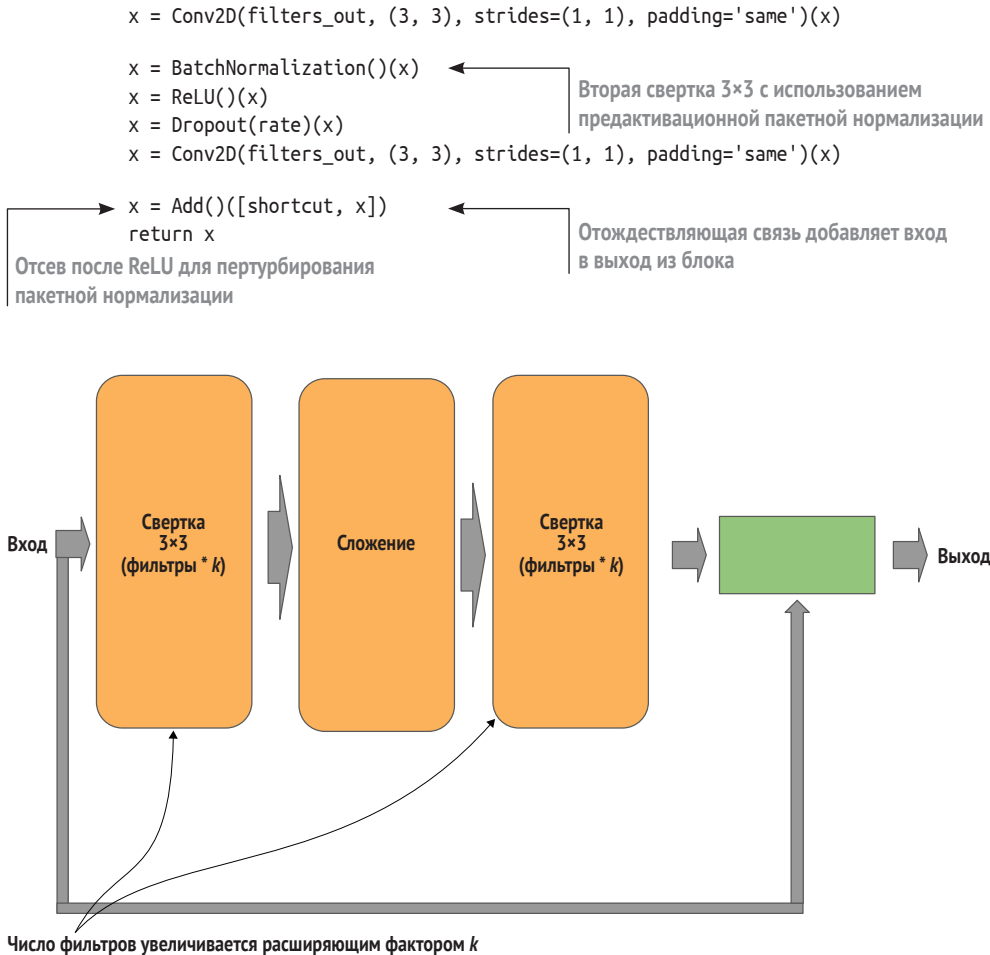


Рис. 6.27 Широкий остаточный блок с отождествляющей аббревиатурой

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для WRN находится в репозитории на GitHub (<http://mng.bz/n2oa>).

6.6 За пределами компьютерного зрения: структурированные данные

Давайте посмотрим на то, как развивались концепции широкого и глубокого слоев в моделях структурированных данных. До 2016 года в большинстве приложений структурированных данных продолжали использоваться классические методы машинного обучения, в отличие от глубокого обучения. В отличие от неструктурированных данных, используемых в компьютерном зрении, структурирован-

ные данные имеют большое разнообразие входных данных, включая числовые, категориальные и сконструированные признаковые. Этот диапазон входных данных означал, что глубокое погружение в слои плотных слоев было не столь эффективным для получения моделей, способных усваивать нелинейные взаимосвязи между входными признаками и соответствующими метками.

На рис. 6.28 показан подход к применению глубокого обучения к структурным данным до 2016 года. При таком подходе все признаковые данные обрабатываются последовательностью плотных слоев – погружаясь вглубь, где скрытые плотные слои по сути являются учениками. Данные на выходе из последнего плотного слоя затем передаются задачному компоненту. Задачный компонент сопоставим с задачным компонентом в компьютерном зрении. Выходом из последнего плотного слоя уже является 1-мерный вектор. Может иметься некое дополнительное сведение вектора, которое затем передается на окончательный плотный слой с активационной функцией, соответствующей задаче: линейной или ReLU для регрессии, сигмоидальной для двоичной классификации и софтмаксной для мультиклассовой классификации.

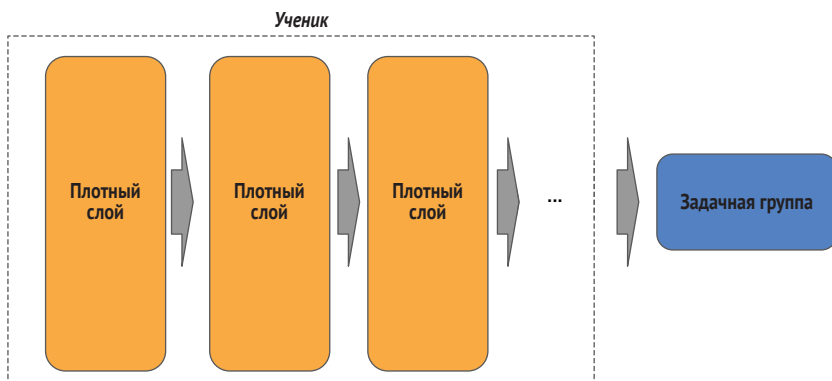


Рис. 6.28 В подходе к моделям структурированных данных до 2016 года использовалась глубоководная глубокая нейросеть

Для структурированных данных вы хотите научиться *запоминать* и *обобщать*. Запоминание – это усвоение сопоявлений значений признаков (ковариантных взаимосвязей). Обобщение – это усвоение новых комбинаций признаков, которые не встречались в распределении тренировочных данных, но которые будут встречаться в распределении данных после развертывания.

Для того чтобы проиллюстрировать разницу между запоминанием и обобщением, я буду использовать распознавание лиц. Во время запоминания порции сети учатся фокусироваться на шаблонах конкретных кластеров образцов (например, определенных шаблонах глаз или оттенков кожи).

Будучи сфокусированной, эта часть сети будет сигнализировать о чрезвычайно высокой уверенности на аналогичных примерах, но низкой уверенности в сопоставимых примерах. По мере того как все больше и больше нейронной сети становится сфокусированной, нейронная сеть вырождается в дерево решений. Это сопоставимо с набором правил в классическом искусственном интеллекте в рамках экспертной системы. Если пример соответствует шаблону, который закодировал эксперт, то он распознается. В противном случае его распознать невозможно.

Например, давайте допустим, что нейронная сеть сфокусирована на таких шаблонах, как глаза, оттенок кожи, пирсинг, очки, шляпы, волосая окклюзия и растительность на лице. Затем мы отправляем изображение ребенка с раскрашенным лицом, и модель не распознает лицо. Тогда вы могли бы перетренировать модель изображениями с краской для лица, но при фокусировке вам придется еще больше увеличить емкость модели для запоминания нового шаблона. И затем возникает еще и еще один шаблон – отсюда и проблема с экспертными системами.

В обобщении избыточные кластеры узлов слабо сигнализируют о распознавании шаблона и коллективно действуют как ансамбль в модели. Чем больше избыточных слабо сигнализирующих кластеров в модели, тем больше возможность, что модель будет обобщать, чтобы распознавать шаблон, на котором она не была натренирована.

Затем, в 2016 году, Google Research опубликовала модельную архитектуру широкой и глубокой сети и соответствующую статью «Широкое и глубокое обучение для рекомендательных систем» Хэн-Цзы Ченга и соавт. (Wide & Deep Learning for Recommender Systems, by Heng-Tze Cheng et al., <https://arxiv.org/pdf/1606.07792.pdf>). Хотя в документе конкретно говорилось об усовершенствовании рекомендательных моделей, эта модель широко использовалась в различных типах моделей структурированных данных. Предоставление рекомендаций было интересной задачей, поскольку в ней используется как обобщение, так и запоминание. Цель состояла в том, чтобы давать нишевые рекомендации с высокоценностной конверсией, которые требовали обобщения, в дополнение к запоминанию широко распространенных сопоявлений (co-occurrence). Широкая и глубокая архитектура сочетает в одной модели как запоминание, так и обобщение. По сути, это две модели, которые объединяются в задачном компоненте.

На рис. 6.29 показана широкая и глубокая архитектура. Эта архитектура также является мультимодальной архитектурой, поскольку она принимает два отдельных входа разных типов.

Давайте погрузимся в эту архитектуру немного глубже. Ученический компонент состоит из двух разделов: многослойной глубокой нейронной сети и однослойного широкого плотного слоя. Широкий плотный слой действует как линейный регрессор и запоминает высокочастотные сопоявления. Глубокая нейронная сеть усваивает нелинейность

и обобщает на низкочастотные (редкие) сопоявления и сопоявления, не замеченные в тренировочных данных. На вход в широкий плотный слой поступают базовые признаки (не перекрестные признаки), которые были предобработаны, и преобразованные признаки (например, кодированием с одним активным состоянием категориальных признаков). Они поступают непосредственно в широкий плотный слой, и в силу этого стержень отсутствует. На вход в многослойную плотную нейронную сеть подаются базовые признаки и перекрестные признаки. В этом случае стержневой компонент конвертирует объединенные признаки во вложение с помощью кодировщика.

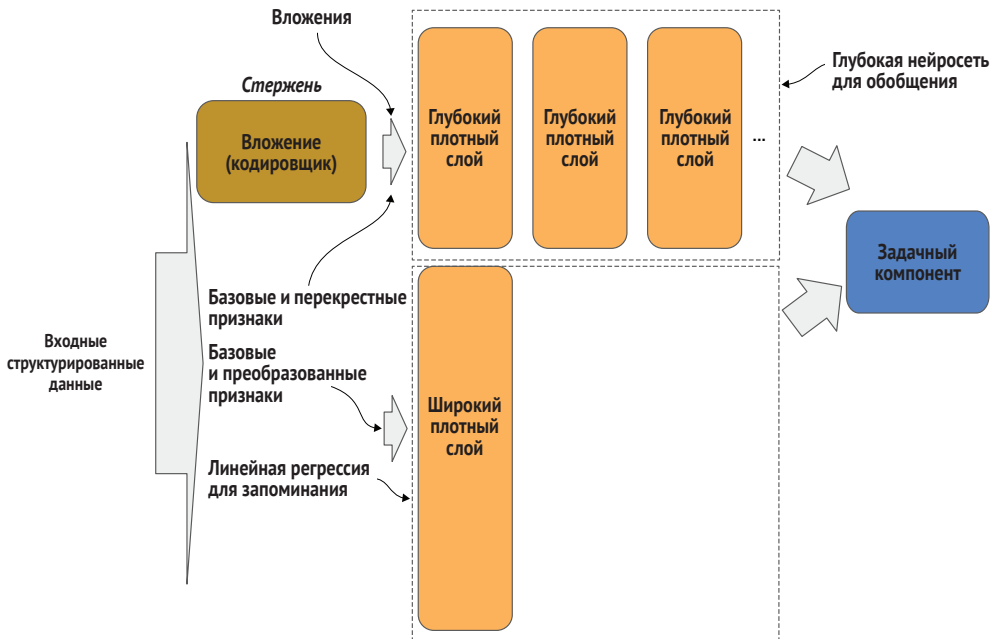


Рис. 6.29 Входы в модель делятся между широким и глубоким слоями, а выходы из слоев объединяются для задачного компонента

Данные на выходе из широкого плотного слоя и из многослойных глубоких нейронных сетей затем объединяются в задачном компоненте и могут быть дополнительно сведены. Задачный компонент по существу такой же, как и в модели компьютерного зрения. И широкий плотный слой, и слои многослойной глубокой нейронной сети тренируются вместе.

Резюме

- Один из подходов к снижению подверженности запоминанию в более глубоких слоях состоял в использовании параллельных

сверток. Это позволило создавать более мелкие сверточные нейронные сети для решения потребности в сверхъёмкости.

- Эквивалентность представления возникает, когда шаблон сверточного конструирования может быть переработан в еще один шаблон, который является менее дорогостоящим в вычислительном отношении и меньшим (по числу параметров). При переработке модель поддерживает тот же уровень выделения информации (или признаков) при меньших вычислительных потребностях. Это позволяет моделям быть меньше, тренироваться быстрее и сокращать задержки в предсказании.
- Концепция переработки нормальной свертки в меньшую в вычислительном отношении пространственно разделяемую свертку была введена в конструкцию модели Inception. Модель Inception демонстрирует эквивалентность представления в сохранении целевых критериев производительности в наборе данных ImageNet.
- Архитектура ResNeXt ввела шаблон разбивки-преобразования-слияния в параллельных групповых свертках. Этот шаблон увеличил точность по сравнению с предыдущими остаточными сетями, не углубляясь в слои.
- Предназначение переноса пакетной нормализации из пост- в пред-активацию в широких остаточных сетях (WRN) заключалось в повышении точности модели. Преактивационная пакетная нормализация еще больше сократила необходимость углубляться, что, в свою очередь, уменьшило необходимость в регуляризации для предотвращения запоминания. Преактивационный метод увеличил скорость тренировки настолько, что для достижения сопоставимого схождения можно было использовать немного более высокую скорость тренировки.
- Множитель ширины для расширяющихся слоев был добавлен в широкие остаточные сети в качестве метапараметра для отыскания ширины в мелкой широкой остаточной сети. Результатом стала модель, которая показывала такую же высокую результативность (с точки зрения точности), как и более глубокая остаточная сеть.
- В современных моделях глубокого обучения для структурированных данных используются как широкие, так и глубокие слои; широкие слои выполняют запоминание, а глубокие слои делают обобщение.

Альтернативные шаблоны связности

Эта глава охватывает следующие ниже темы:

- понимание альтернативных шаблонов связности для более глубоких и широких слоев;
- повышение точности за счет реиспользования карт признаков, дальнейшего разложения сверток и за счет сдавливания-возбуждения;
- кодирование альтернативно соединенных моделей (DenseNet, Xception, SE-Net) с использованием шаблона процедурного конструирования.

Ранее мы рассматривали сверточные сети с глубокими слоями и сверточные сети с широкими слоями. В частности, мы увидели, как соответствующие шаблоны связности между сверточными блоками и внутри них решали проблемы исчезающих и взрывающихся градиентов, а также проблему запоминания из-за сверхъемкости.

Эти методы увеличения глубоких и широких слоев, наряду с регуляризацией (добавлением шума с целью сокращения переподгонки) в более глубоких слоях, уменьшили проблему с запоминанием, но, безусловно, ее не устранили. Таким образом, исследователи занимались разведыванием других шаблонов связности внутри и между остаточными сверточными блоками для дальнейшего сокращения запоминания без существенного увеличения числа параметров и вычислительных операций.

В этой главе мы рассмотрим три таких альтернативных шаблона связности: DenseNet, Xception и SE-Net. Все эти шаблоны преследо-

вали схожие цели: снижение сложности вычислений в компоненте связности. Но они разошлись в своих подходах к проблеме. Давайте сначала рассмотрим эти различия. Затем оставшаяся часть главы будет посвящена рассмотрению особенностей каждого шаблона.

В 2017 году исследователи из Корнельского университета, Университета Цинхуа и Facebook AI Research утверждали, что остаточная связь в обычных остаточных блоках лишь частично позволяла более глубоким слоям использовать выделение признаков из более ранних слоев. Выполняя матричное сложение входных данных с выходными, признаковая информация из входных данных постепенно разбавляется по мере продвижения к более глубоким слоям. Авторы предложили использовать конкатенацию карт признаков, которую они вместо матричного сложения называли *реиспользованием признаков*. Их рассуждения заключались в том, что карты признаков на выходе из каждого остаточного блока будут реиспользоваться во всех оставшихся (более глубоких) слоях. Для того чтобы модельные параметры увеличивались в размерах по мере того, как карты признаков накапливаются вплоть до более глубоких слоев, они внедрили агрессивную редукцию размерности карт признаков между сверточными группами. В своем абляционном исследовании авторы DenseNet добились более высокой производительности, чем предыдущие точно-блочные сети.

В том же году Франсуа Шолле (François Chollet), создатель Keras, представил архитектуру Xception как модернизацию модели Inception v3 в новый шаблон потока. Новый шаблон состоял из входного, серединного и выходного потоков, в отличие от предыдущих конструкций Inception. Хотя этот новый шаблон потока принят другими исследователями не был, они приняли предложенное Шолле дальнейшее разложение нормальных и разделяемых сверток на свертки, разделяемые по глубине. Этот процесс сокращает число матричных операций, сохраняя при этом эквивалентность представления (подробнее об этом в ближайшее время). Указанное разложение продолжает появляться во многих передовых моделях, в особенности в тех, которые предназначены для устройств с ограниченными возможностями памяти и вычислений, таких как мобильные устройства.

Позже, в 2017 году, исследователи из Китайской академии наук и Оксфордского университета представили еще один шаблон связности для остаточных блоков, который можно было переоборудовать в традиционные остаточные сети. Шаблон связности SE-Net, как стало известно, вставлял микроблок (именуемый связью SE) между выходом из остаточного блока и операцией матричного сложения с входом в блок. Указанный микроблок производил агрессивную редукцию размерности, или *сдавливание*, на выходных картах признаков с последующим расширением размерности, или *возбуждением*. Исследователи выдвинули гипотезу, что указанный шаг сдавливания и возбуждения будет приводить к большей обобщенности карт признаков. Они вставили связи SE в ResNet и ResNeXt и продемонстри-

ровали улучшение производительности в среднем на 2 % на примерах, не встречавшихся во время тестирования (отложенных данных).

Теперь, когда у нас есть общая картина, давайте рассмотрим детали решения этими тремя шаблонами проблемы снижения сложности на уровне соединения.

7.1 DenseNet: плотносвязанная сверточная нейронная сеть

В модели DenseNet была представлена концепция плотносвязанной сверточной сети. Соответствующая статья «Плотносвязанные сверточные сети» Гао Хуана и соавт. (Densely Connected Convolutional Networks, Gao Huang et al., <https://arxiv.org/abs/1608.06993>) получила награду за лучшую статью Конференции по компьютерному зрению и распознаванию образов (CVPR) 2017 года. Конструкция основана на принципе, согласно которому выход из каждого остаточно-блочного слоя соединен со входом в каждый последующий остаточно-блочный слой.

В силу этого расширяется концепция отождествляющих связей в остаточных блоках (рассмотрена в главе 4). В данном разделе содержится подробная информация о макроархитектуре, компонентах групп и блоков, а также соответствующих конструктивных принципах.

7.1.1 Плотная группа

До DenseNet отождествляющая связь между входом и выходом из остаточного блока комбинировалась матричным сложением. Напротив, в плотном блоке вход в остаточный блок комбинируется с выходом из остаточного блока. Это изменение ввело концепцию *реиспользования (карт) признаков*.

На рис. 7.1 вы видите разницу в связности между остаточным блоком и плотным остаточным блоком. В остаточном блоке значения входных карт признаков складываются с выходными картами признаков. Хотя при этом в блоке удерживалась некоторая информация, ее можно рассматривать как разбавленную операцией сложения. В остаточном блоке версии DenseNet входные карты признаков полностью удерживаются, поэтому разбавления не происходит.

Замена матричного сложения на конкатенацию имеет следующие преимущества:

- дальнейшее облегчение проблемы исчезающего градиента в более глубоких слоях;
- дальнейшее сокращение вычислительной сложности (параметров) с помощью более узких карт признаков.

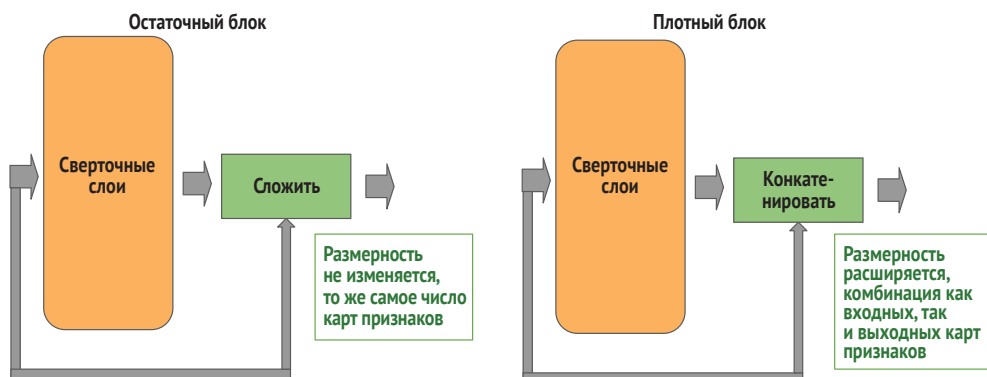


Рис. 7.1 Остаточный блок в сравнении с плотным блоком: в плотном блоке вместо операции матричного сложения используется операция матричной конкатенации

В конкатенации расстояние между выходом (из классификатора) и картами признаков сокращается. Сокращенное расстояние уменьшает проблему исчезающего градиента, позволяя создавать более глубокие сети, которые могли бы производить более высокую точность.

Реиспользование карт признаков имеет эквивалентность представления с предыдущей операцией матричного сложения, но с существенно меньшим числом фильтров. Авторы называют эту компоновку *более узкими* слоями. С более узкими слоями совокупное число тренируемых параметров сокращается. Авторы выдвинули гипотезу, что реиспользование признаков позволило модели углубляться в слои для большей точности, не подвергаясь воздействию исчезающих градиентов или запоминания.

Вот пример для сравнения. Давайте допустим, что выходы из слоя представляют собой карты признаков размером $28 \times 28 \times 10$. После матричного сложения выходы продолжают оставаться картами признаков размером $28 \times 28 \times 10$. Значения внутри них являются сложением входа и выхода из остаточного блока и, следовательно, не удерживают исходные значения – другими словами, они были слиты воедино. В плотном блоке входные карты признаков конкатенируются – не сливаются вместе – с выходом из остаточного блока, тем самым сохраняя исходное значение отождествляющей связи. В нашем примере при входе и выходе размером $28 \times 28 \times 10$ выход после конкатенации будет иметь размер $28 \times 28 \times 20$. Переходя к следующему блоку, выход будет $28 \times 28 \times 40$.

В таком ключе выход из каждого слоя конкатенируется с входом из каждого последующего слоя, что приводит к формулировке «*тесносвязанный*» для описания моделей такого рода. На рис. 7.2 показана общая конструкция и отождествляющее связывание между остаточными блоками в плотной группе.

Как вы видите, плотная группа состоит из нескольких плотных блоков. Каждый плотный блок состоит из остаточного блока (без

отождествляющей связи) и отождествляющей связи из входа в остаточный блок с выходом. Входные и выходные карты признаков затем конкатенируются в единый выход, который становится входом в следующий плотный блок. В таком ключе карты признаков, выдаваемые из каждого плотного блока, реиспользуются (коллективно) с каждым последующим плотным блоком.

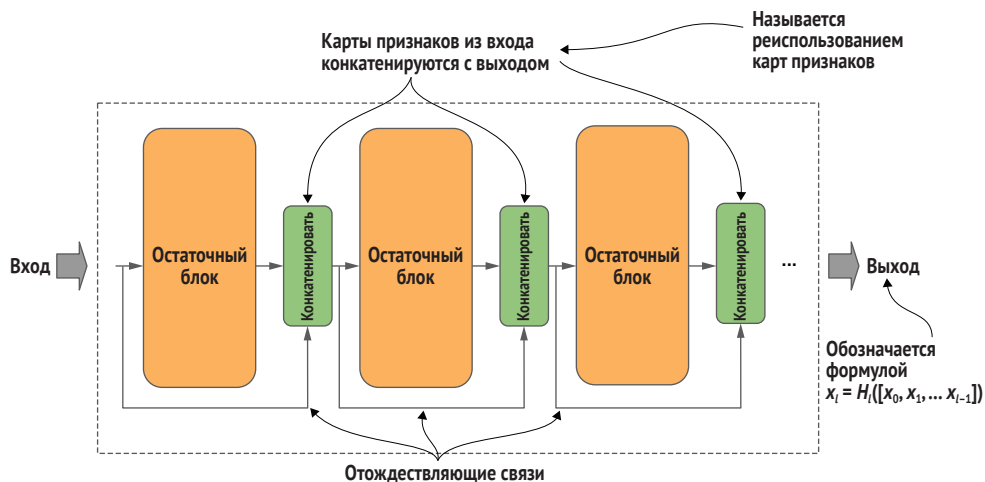


Рис. 7.2 В этой микроархитектуре с плотной группой между выходом из остаточного блока и входом (отождествляющая связь) используется операция конкатенации матриц

Исследователи архитектуры DenseNet ввели метипараметр k , который указывал число фильтров в каждой сверточной группе. Они испробовали $k = 12, 24$ и 32 . Для ImageNet они использовали $k = 32$ с четырьмя плотными группами. Они обнаружили, что могут получать сопоставимые результаты с сетями ResNet с половиной параметров. Например, они натренировали модель DenseNet с параметрами, сопоставимыми с сетью ResNet50, всего с 20 млн параметров, и получили сопоставимые результаты с более глубокой сетью ResNet101 с 40 млн параметров.

Следующий ниже исходный код является примером имплементации плотной группы. Число плотных остаточных блоков задается параметром `n_blocks`, число выходных фильтров – параметром `n_filters`, а фактор сжатия – параметром `compression`. Для последней группы отсутствие переходного блока (мы рассмотрим их далее) обозначается установкой параметра `compression` равным `None`:

```
def group(x, n_blocks, n_filters, compression=None):
    """ Построить плотную группу
    x : данные на входе в группу
    n_blocks : число остаточных блоков в плотном блоке
    n_filters : число фильтров в сверточном слое в остаточном блоке
    compression : объем, на который следует сократить карты признаков
```

```

"""
for _ in range(n_blocks):
    x = dense_block(x, n_filters)

if compression is not None:
    x = trans_block(x, reduction)
return x

```

Строит группу плотно соединенных остаточных блоков

Строит посреднический переходный блок

Давайте еще раз обсудим вопрос, почему в DenseNet и других передовых моделях нет окончательного сведения карт признаков перед задачным компонентом (например, классификатором). Эти модели выполняют процесс выделения признаков внутри блоков и обобщение признаков в конце группы – данный процесс мы называем *усвоением признаков*. Каждая группа резюмирует признаки, которые она усвоила, чтобы сократить вычислительную сложность для дальнейшей обработки карт признаков последующими группами. Окончательные (несведенные) карты признаков последней группы оптимизированы по размеру под представление признаков в виде высокоразмерного кодирования в латентном пространстве. Здесь следует напомнить, что в многозадачных моделях, таких как обнаружение признаков, латентное пространство используется коллективно между задачами (или, в случае консолидации моделей, между модельными интерфейсами).

Как только окончательные карты признаков входят в задачный компонент, они сводятся в последний раз – но они сводятся в ключе, который является оптимальным для усвоения задачи вместо резюмирования признаков. Этот последний шаг сведения в задачном компоненте является бутылочным слоем, а его выход называется *низкоразмерным вложением* латентного пространства, которое также может использоваться коллективно с другими задачами и моделями.

Архитектура DenseNet состоит из четырех плотных групп, каждая из которых состоит из конфигурируемого числа плотных блоков. Теперь давайте рассмотрим строительство и конструкцию плотного блока.

7.1.2 Плотный блок

Остаточный блок в модели DenseNet использует шаблон B(1, 3), то есть свертку 1×1 , за которой следует свертка 3×3 . Однако свертка 1×1 является линейной проекцией, а не бутылочным горлышком: 1×1 расширяет число выходных карт признаков (фильтров) на фактор расширения 4. Затем 3×3 выполняет редукцию размерности, восстанавливая число выходных карт признаков до того же числа, что и у входных карт признаков.

На рис. 7.3 показано расширение и редукция размерности карт признаков в остаточном плотном блоке. Обратите внимание, что число и размер входных и выходных карт признаков остаются неизменными. Внутри блока линейная проекция 1×1 расширяет число

карт признаков, тогда как последующая свертка 3×3 выполняет как выделение признаков, так и сокращение карт признаков. Именно этот последний сверточный слой восстанавливает число и размер карт признаков на выходе, чтобы они совпадали с тем, что были на входе, – данный процесс называется *восстановлением размерности*.




Рис. 7.3 В расширении и редукции размерности в сверточных слоях остаточного плотного блока число и размер карт признаков на входе и выходе одинаковы

Рисунок 7.4 иллюстрирует остаточный плотный блок, который состоит из следующих элементов:

- линейно-проекционная свертка 1×1 , которая увеличивает число карт признаков в четыре раза;
- свертка 3×3 , которая выделяет признаки и восстанавливает число карт признаков;
- операция, которая конкатенирует входные карты признаков остаточного блока и его данные на выходе.

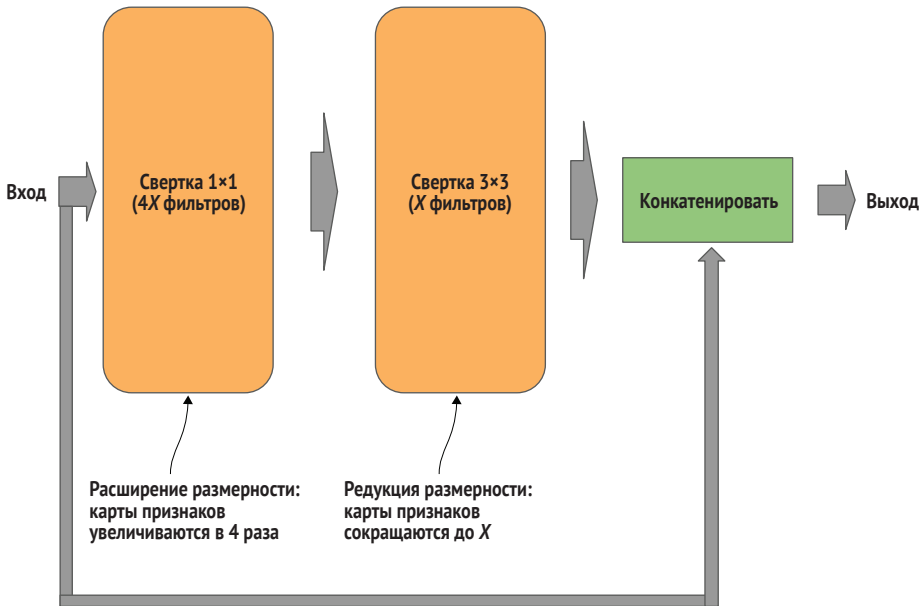


Рис. 7.4 Остаточный плотный блок с отождествляющей аббревиатурой, использующий операцию конкатенации для реиспользования признаков

В архитектуре DenseNet также была принята современная традиция использовать предактивационную пакетную нормализацию (BN-ReLU-Conv) для повышения точности. В постактизации активация ReLU и пакетная нормализация происходят *после* свертки. В предактивации пакетная нормализация и ReLU происходят *перед* сверткой.

Предыдущие исследователи обнаружили, что при переходе от пост- к предактивации точность моделей увеличивалась с 0.5 до 2%. (Например, исследователи ResNet v2, как было представлено в статье «Соотнесения идентичности в глубоких остаточных сетях» (Identity Mappings in Deep Residual Networks) [<https://arxiv.org/abs/1603.05027>].)

Следующий ниже исходный код является примером имплементации плотного остаточного блока, который состоит из следующих шагов:

- 1 сохранение копии входных карт признаков в переменной `shortcut`;
- 2 предактивационная линейная проекция 1×1 , которая увеличивает число карт признаков в четыре раза;
- 3 предактивационная свертка 3×3 для выделения признаков и восстановления числа карт признаков;
- 4 конкатенация сохраненных входных карт признаков с выходными картами признаков с целью реиспользования признаков.

```

shortcut = x  ← Запоминает данные на входе
x = BatchNormalization()(x)
x = ReLU()(x)
x = Conv2D(4 * n_filters, (1, 1), strides=(1, 1))(x)

```

Расширение размерности,
расширяет фильтры в 4 раза
(DenseNet-B)

```

x = BatchNormalization()(x)
x = ReLU()(x)
x = Conv2D(n_filters, (3, 3), strides=(1, 1), padding='same')(x)

```

→ `x = Concatenate()([shortcut, x])`
 Конкатенирует вход (тождество) с выходом из остаточного блока, где конкатенация обеспечивает реиспользование признаков между слоями

Бутылочная свертка 3×3 с `padding='same'`, чтобы сберечь форму карт признаков

7.1.3 Макроархитектура DenseNet

В учебном компоненте *переходный блок* вставляется между каждой плотной группой для дальнейшего снижения вычислительной сложности. Переходный блок представляет собой пошаговую свертку, также именуемую *сведением признаков*, используемую для сокращения совокупного размера конкатенированных карт признаков (реиспользование признаков) по мере их перемещения из одной плотной группы в следующую. Без этого сокращения совокупный размер карт признаков поступательно удваивался бы в расчете на каждый плотный блок, что привело бы к резкому увеличению числа тренируемых параметров. Сокращая число параметров, модель DenseNet может углубляться в слои только с линейным увеличением в числе параметров.

Прежде чем мы рассмотрим архитектуру переходного блока, сначала давайте взглянем на то, где он вписывается в учебный компонент. На рис. 7.5 вы видите, что учебный компонент состоит из четырех плотных групп, и переходный блок находится между каждой плотной группой.

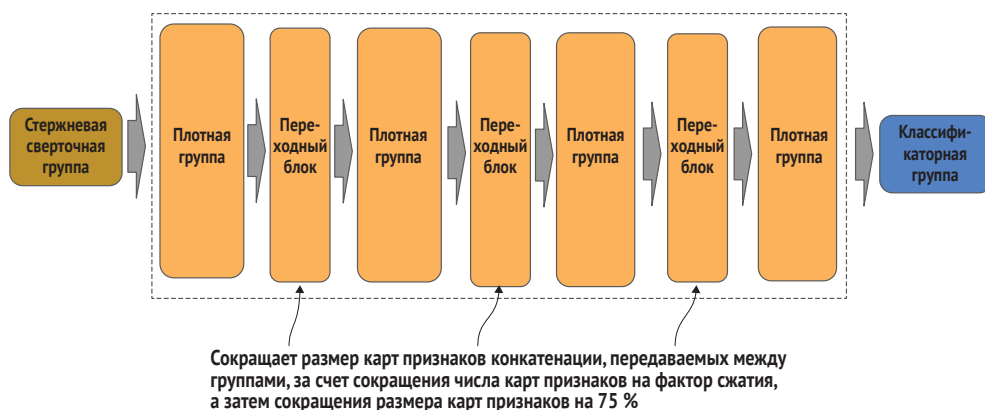


Рис. 7.5 Макроархитектура DenseNet, показывающая переходные блоки между плотными группами

Теперь давайте внимательно рассмотрим переходный блок между каждой плотной группой.

7.1.4 Плотный переходный блок

Переходный блок состоит из двух шагов:

- бутылочная свертка 1×1 , которая сокращает число выходных карт признаков (каналов) на фактор сжатия C ;
- пошаговое среднее сведение, которое следует по бутылочному горлышку и сокращает размер каждой карты признаков на 75 %. Когда мы говорим «пошаговый», мы обычно имеем в виду шаг 2. А шаг 2 сокращает размеры признака по высоте и ширине вдвое, что сокращает число пикселей на четверть (25 %).

Указанный процесс проиллюстрирован на рис. 7.6. Здесь надпись «фильтры / C » представляет сжатие карт признаков в бутылочной свертке 1×1 , которое сокращает число карт признаков. Следующее за этим среднее сведение выполняется пошагово, что сокращает размер уже сокращенного числа карт признаков.

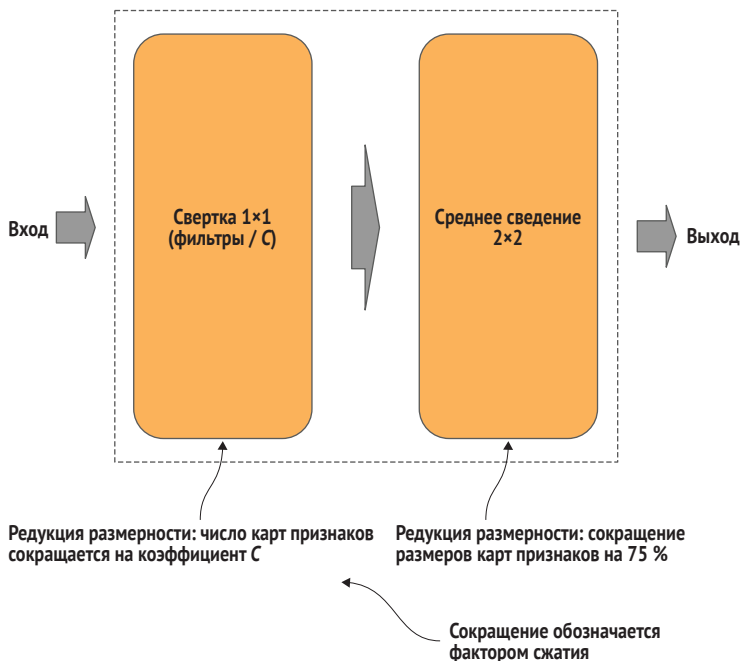


Рис. 7.6 В плотном переходном блоке размерность карт признаков сокращается как за счет бутылочной свертки 1×1 , так и за счет слоя пошагового среднего сведения

Теперь, как же на самом деле работает это сжатие? Как вы видите на рис. 7.7, мы начинаем с входа из восьми карт признаков, каждая размером $H \times W$, которые в общей сложности могут быть представлены как $H \times W \times 8$. Коэффициент сжатия в бутылочной свертке 1×1 равен 2. Поэтому бутылочное горлышко берет входные данные, а затем

выдает половину числа карт признаков, которое в данном примере равно 4. Эту величину можно представить как $H \times W \times 4$. Пошаговое среднее сведение затем сокращает размерность 4 карт признаков наполовину, что в итоге приводит к окончательному выходному размеру $0.5H \times 0.5W \times 4$.




Рис. 7.7 Демонстрация хода сокращения карт признаков (сжатия) в переходном блоке

В целях сжатия числа карт признаков необходимо знать число карт признаков (каналов), поступающих в переходный блок. В следующем ниже примере исходного кода это число получается с помощью `x.shape[-1]`. Мы используем индекс `-1` для обозначения последней размерности в форме входного тензора (B, H, W, C), то есть числа каналов. Число карт признаков во входном тензоре затем умножается на фактор `compression` (который находится между 0 и 1). Обратите внимание, что в Python операции умножения выполняются со значениями с плавающей точкой, поэтому мы приводим результат назад к целочисленному:

<p>Вычисляет сокращение (сжатие) числа карт признаков (DenseNet-C)</p> <pre> n_filters = int(x.shape[-1]) * compression) x = BatchNormalization()(x) x = Conv2D(n_filters, (1, 1), strides=(1, 1))(x) x = AveragePooling2D((2, 2), strides=(2, 2))(x) </pre>	<p>Бутылочная свертка 1×1 с использованием формы BN-LI-Conv пакетной нормализации</p>
	<p>Использует среднее (среднеарифметическое) значение при сведении для сокращения на 75 %</p>

Полная версия кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для DenseNet доступна в репозитории на GitHub (<http://mng.bz/6N0o>).

7.2 Xception: экстремальное начало

Архитектура *Xception* (Экстремальное начало, от англ. Extreme Inception), как отмечалось ранее, была представлена создателем каркаса Keras Франсуа Шолле в Google в 2017 году в качестве предлагаемого дальнейшего усовершенствования по сравнению с архитектурой Inception v3. В своей статье «Xception: глубокое обучение со сверт-

ками, разделяемыми по глубине» (Xception: Deep Learning with Depthwise Separable Convolutions, François Chollet, <https://arxiv.org/pdf/1610.02357.pdf>) Шолле утверждал, что успех модуля в стиле Inception был основан на разложении, которое существенно отстыковало пространственные корреляции от канальных корреляций. Эта отстыковка привела к сокращению числа параметров при сохранении представительной мощности. Он предположил, что мы могли бы еще больше сократить число параметров, сохранив представительную мощность, полностью отстыковав пространственные и канальные корреляции. Не волнуйтесь, если эти идеи по отстыковке покажутся вам немного сложными; вы найдете более подробное объяснение в разделе 7.2.5.

В своей статье Шолле сделал еще одно важное заявление: он утверждал, что его версия архитектуры для Xception на самом деле проще, чем архитектура Inception, и может быть закодирована всего в 30–40 строках с использованием библиотеки высокого уровня, такой как Keras. Шолле основывал свой вывод на экспериментах, сравнивающих точность Inception v3 с Xception на наборах данных ImageNet и внутреннего для Google совместного фотодерева (Joint Foto Tree, аббр. JFT). В обеих моделях он использовал одинаковое число параметров, поэтому считал, что любое повышение точности было связано с более эффективным использованием параметров. Набор данных JFT состоит из 350 млн изображений и 17 000 категорий; Xception превзошел Inception на 4.3 % на наборе данных JFT. В его экспериментах с набором данных ImageNet, состоящим из 1.2 млн изображений и 1000 категорий, разница в точности была незначительной.

Между Inception v3 и Xception произошли два первостепенных изменения:

- реорганизация использования архитектурой Inception трех остаточных групп в стиле Inception (A, B и C) во входной, срединной и выходной потоки. В соответствии с этим новым подходом стержневая группа становится частью входа, а классификатор становится частью выхода, что снижает структурную сложность остаточных блоков в стиле Inception;
- разложение свертки на пространственно разделяемую свертку в блоке Inception v3 заменяется сверткой, разделяемой по глубине, что сокращает число операций матричного умножения на 83 %.

Как и в Inception v3, в Xception используется постактивационная пакетная нормализация (Conv-BN-ReLU).

Давайте взглянем на совокупную макроархитектуру, а затем рассмотрим детали модернизированных компонентов (входной, выходной и срединной потоки). В конце этого раздела мы вернемся к тому, с чего начали, и я объясню разложение пространственных сверток на свертки, разделяемые по глубине.

7.2.1 Архитектура Xception

Шолле взял традиционную компоновку стержень–ученик–классификатор и перегруппировал ее во входной поток, срединный поток и выходной поток. Вы видите это на рис. 7.8, на котором показана архитектура Xception, перегруппированная и модифицированная в шаблон конструирования процедурного реиспользования. Вход и середина представляют усвоение признаков, а выходной поток представляет усвоение классификации.

Хотя я читал статью Шолле несколько раз, я не могу найти оправдания для описания архитектуры как имеющей входной, срединный и выходной потоки. Думаю, что было бы яснее просто назвать эти три *стиля* остаточных групп в ученическом компоненте, поддерживая традицию их именования как A, B и C. В статье, по всей видимости, делается намек на то, что его решение было попыткой упростить то, что он называл сложной архитектурой Inception. Он хотел этого упрощения, чтобы архитектура могла быть написана в 30–40 строках библиотеки высокого уровня, такой как Keras или TensorFlow-Slim, при сохранении сопоставимого числа параметров. В любом случае, последующие исследователи не приняли терминологию Шолле о входном, срединном и выходном потоках.




Рис. 7.8 В макроархитектуре Xception главенствующие компоненты перегруппированы во входной, срединный и выходной потоки. И вот как они вписываются в стержневой, ученический и задачный компоненты

Как вы видите, стержневой компонент включен во входной поток, а классификационный компонент – в выходной поток. Остаточные

сверточные группы от входного потока до выходного в совокупности образуют эквивалент учебного компонента.

Скелетная имплементация архитектуры Xception показывает, как исходный код делится на раздел входного, срединного и выходного потоков. Входной поток далее подразделяется на стержень и корпус, а выходной поток – на классификатор и корпус. Эти разделы обозначены в заготовке исходного кода тремя функциями верхнего уровня: `entryFlow()`, `middleFlow()` и `exitFlow()`. Функция `entryFlow()` имеет вложенную функцию `stem()` для обозначения включения стержня во входной поток, а функция `exitFlow()` имеет вложенную функцию `classifier()` для обозначения включения классификатора в выходной поток.

Для краткости я опустил детали тел функций. Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для Xception доступна в репозитории на GitHub (<http://mng.bz/5WzB>).

```
def entryFlow(inputs):
    """ Создать раздел входного потока
        inputs : тензор на входе в нейронную сеть
    """
    def stem(inputs):
        """ Создать стержневой вход в the нейронную сеть
            inputs : тензор на входе в нейронную сеть
        """
        return x

    x = stem(inputs)
    for n_filters in [128, 256, 728]:
        x = projection_block(x, n_filters)
    return x

def middleFlow(x):
    """ Создать раздел срединного потока
        inputs : тензор на входе в раздел
    """
    for _ in range(8):
        x = residual_block(x, 728)
    return x

def exitFlow(x, n_classes):
    """ Создать раздел выходного потока
        x : вход в раздел выходного потока
        n_classes : число выходных классов
    """
    def classifier(x, n_classes):
        """ Выходной классификатор
            x : вход в классификатор
            n_classes : число выходных классов
        """
```

Стержневой компонент является частью входного потока

Исходный код для краткости удален

Стержневой компонент является частью входного потока

Строит три остаточных блока, используя линейную проекцию

Срединный поток строит 8 идентичных остаточных блоков

Классификаторный компонент является частью выходного потока

```

"""
Срединный поток строит 8 идентичных остаточных блоков
return x
x = classifier(x, n_classes)
return x

inputs = Input(shape=(299, 299, 3))
x = entryFlow(inputs)
x = middleFlow(x)
outputs = exitFlow(x, 1000)
model = Model(inputs, outputs)

```

Исходный код для краткости удален

Исходный код для краткости удален

Создает входной вектор формы (299, 299, 3)

Строит входной поток

Строит срединный поток

Строит выходной поток для 100 классов

7.2.2 Входной поток Xception

Компонент «входной поток» состоит из стержневой сверточной группы, за которой следуют три остаточных блока в стиле входного потока Xception, поочередно выдающие 128, 256 и 728 карт признаков. На рис. 7.9 показан входной поток и то, как стержневая группа вписывается в него в качестве подкомпонента.

Стержень состоит из стопки из двух сверток 3×3 , как показано на рис. 7.10. Вторая свертка 3×3 удваивает число выходных карт признаков (расширение размерности), и одна из сверток выполняется пошагово для сведения признаков (редукции размерности).

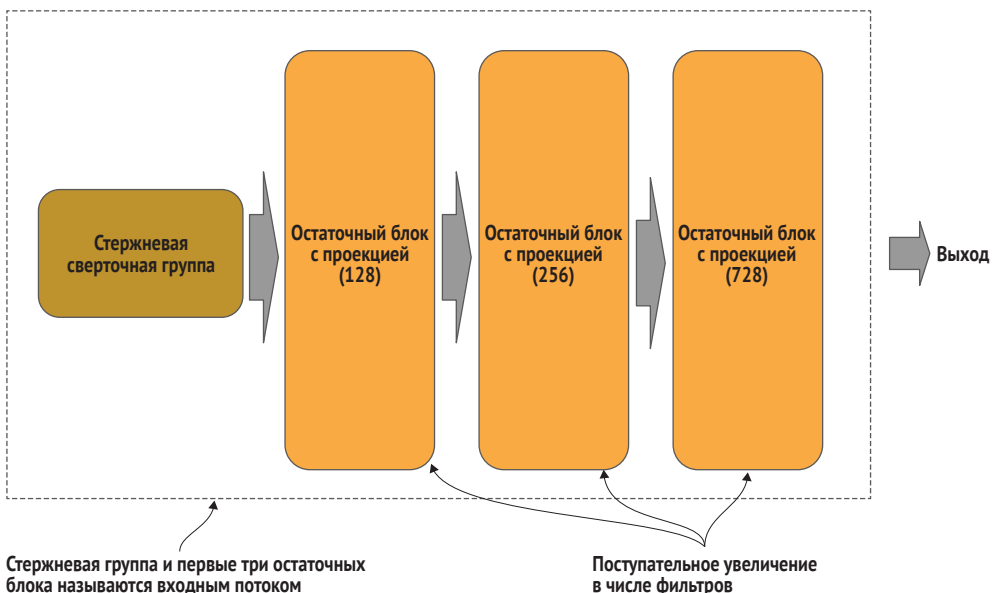


Рис. 7.9 Микроархитектура входного потока Xception

Для архитектуры Xception число фильтров для стопки равно соответственно 32 и 64, что является широко принятой традицией. Первая свертка в стопке, которая является пошаговой, была выбрана для сокращения числа параметров до второй свертки 3×3 в стопке. Другая традиция касается второй свертки 3×3 , которая предназначена для резюмирования признаков и отказывается от сокращения в параметрах.

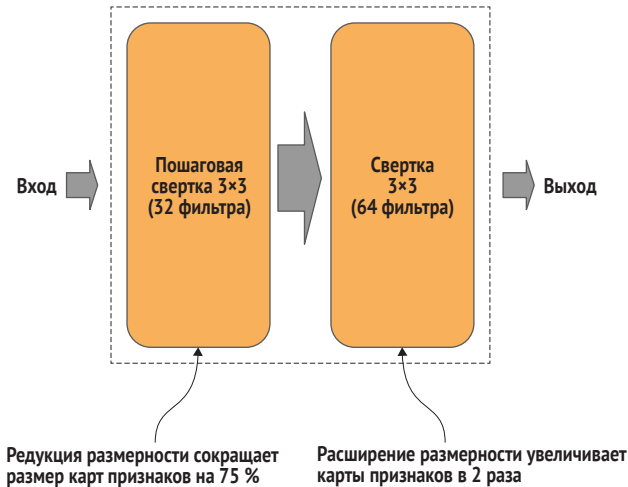


Рис. 7.10 Конструкция слоя стержневой группы Xception для стопки из двух сверток 3×3

Далее следует остаточный блок в стиле входного потока, показанный на рис. 7.11. Стиль входного потока использует остаточный блок $B(3, 3)$, за которым следуют максимальное сведение и линейная проекция 1×1 на отождествляющие связи. Свертки 3×3 представляют собой свертки, разделяемые по глубине (SeparableConv2D), в отличие от архитектуры Inception v3, в которой использовалась комбинация нормальных и пространственно разделяемых сверток. В максимальном сведении используется размер сведения 3×3 , что позволяет выдавать максимальное значение из 9-пиксельного окна (по сравнению с 4 пикселями для 2×2). Обратите внимание, что линейная проекция 1×1 также выполняется пошагово, сокращая размер карт признаков, чтобы совпадать с размером сокращения карт признаков из остаточного пути слоем максимального сведения.

Теперь давайте рассмотрим пример имплементации остаточного блока в стиле входного потока. Ниже приведен исходный код для следующих элементов:

- 1 линейная проекция 1×1 для увеличения числа карт признаков и сокращения размера, чтобы совпадать с выходом из остаточного пути (shortcut);
- 2 две разделяемые по глубине свертки размером 3×3 ;

- 3 операция матричного сложения карт признаков из линейно-проекционной связи (shortcut) с выходом из остаточного пути.




Рис. 7.11 Остаточный блок архитектуры Xception с линейно-проекционным сокращением

В проекционной аббревиатуре используется пошаговая свертка для сокращения размера карт признаков при одновременном удвоении числа фильтров, чтобы совпадать с выходом из блока для операции матричного сложения

```
def projection_block(x, n_filters):
    """ Создать остаточный блок, используя разделяемые по глубине свертки с
        проекционной аббревиатурой
        x : данные на входе в остаточный блок
        n_filters: число фильтров
    """
    shortcut = Conv2D(n_filters, (1, 1), strides=(2, 2), padding='same')(x)
    shortcut = BatchNormalization()(shortcut)

    x = SeparableConv2D(n_filters, (3, 3), padding='same')(x)
    x = BatchNormalization()(x)
    x = ReLU()(x)

    x = SeparableConv2D(n_filters, (3, 3), padding='same')(x)
    x = BatchNormalization()(x)
    x = ReLU()(x)

    x = MaxPooling2D((3, 3), strides=(2, 2), padding='same')(x)

    x = Add()(x, shortcut)
    return x
```

Первая
разделяемая
по глубине
свертка

Вторая
разделяемая
по глубине
свертка

Сокращает размер карт
признаков на 75 %

Складывает проекционную аббревиатуру
с выходом из блока

7.2.3 Срединный поток модели Xception

Срединный поток состоит из восьми остаточных блоков в стиле срединного потока, каждый из которых выдает 728 карт признаков. Между блоками в группе по традиции принято поддерживать одинаковое число входных/выходных карт признаков; тогда как между группами число карт признаков постепенно увеличивается. В отличие от этого, при использовании Xception число выходных карт признаков во входном и срединном потоках оставалось неизменным, а не увеличилось.

Остаточный блок в стиле срединного потока, показанный на рис. 7.12, использует восемь остаточных блоков $B(3, 3, 3)$. В отличие от остаточного блока входного потока, на отождествляющие связи отсутствует пошаговая линейная проекция 1×1 , поскольку число входных и выходных карт признаков остается одинаковым во всех блоках, и никакого сведения не происходит.

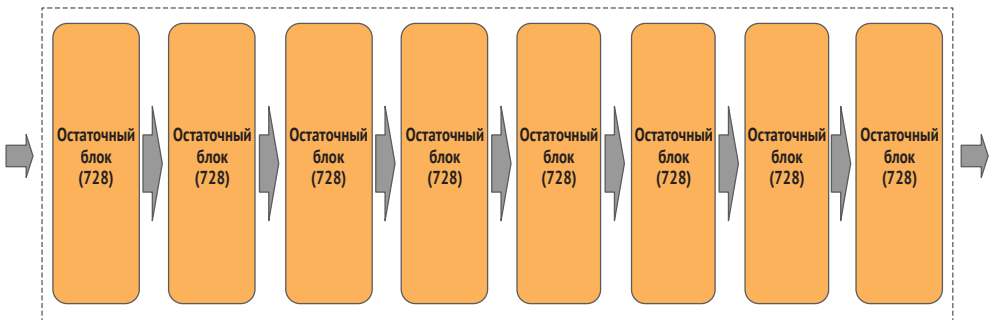


Рис. 7.12 Микроархитектура срединного потока Xception имеет последовательность из восьми идентичных остаточных блоков

Теперь давайте посмотрим, что происходит в каждом из этих остаточных блоков. На рис. 7.13 показаны три свертки 3×3 , которые являются разделяемыми по глубине свертками (SeparableConv2D). (Опять же, мы скоро разберемся, чем, собственно говоря, является разделяемая по глубине свертка.)

Следующий ниже исходный код является примером имплементации остаточного блока в стиле срединного потока, где стиль $B(3, 3, 3)$ имплементирован с использованием разделяемых по глубине сверток (SeparableConv2D):

```
def residual_block(x, n_filters):
    """ Создать остаточный блок, используя разделяемые по глубине свертки
        x : вход в остаточный блок
        n_filters: число фильтров
    """

    shortcut = x
```

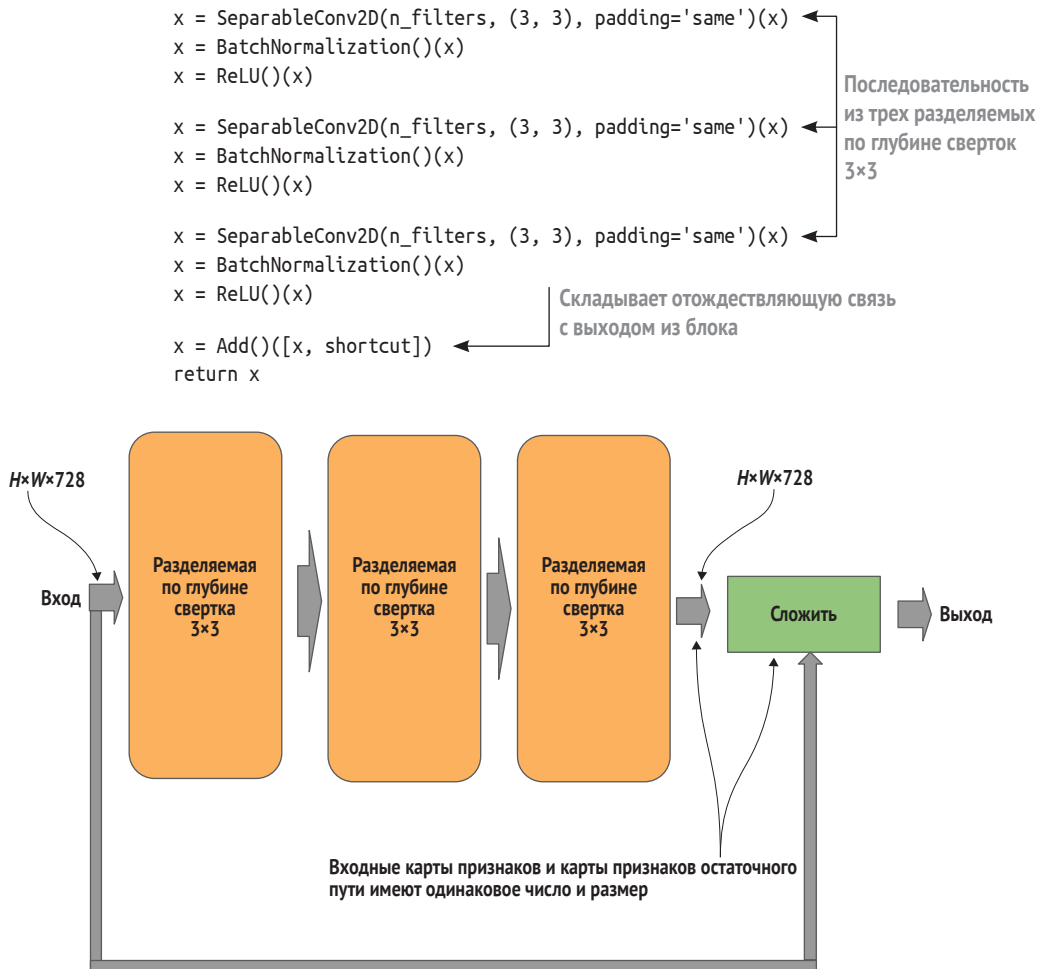



Рис. 7.13 Срединный поток остаточного блока с отождествляющей аббревиатурой: число и размер как входных карт признаков, так и карт признаков остаточного пути одинаковы для операции матричного сложения

7.2.4 Выходной поток архитектуры Xception

Теперь перейдем к выходному потоку. Он состоит из одного остаточного блока в стиле выходного потока, за которым следует сверточный (неостаточный) блок, а затем классификатор. Классификаторная группа, как показано на рис. 7.14, является подкомпонентом выходного потока.

Выходной поток принимает на входе 728 карт признаков и выдает из срединного потока и поступательно увеличивает число карт признаков до 2048 перед классификатором. Сравните это с традицией для крупных сверточных нейросетей, таких как Inception v3

и ResNet, которые генерируют 2048 окончательных карт признаков перед бутылочным слоем, создавая так называемую *высокоразмерную кодировку*.




Рис. 7.14 Выходной поток Xception постепенно увеличивает число карт признаков

Давайте взглянем крупным планом на этот единственный остаточный блок в стиле выходного потока на рис. 7.15. Указанный остаточный блок представляет собой $B(3,3)$ с двумя свертками, выдающими соответственно 728 и 1024 карты признаков. За двумя свертками следует максимальное сведение с размером сведения 3×3 , а затем линейная проекция 1×1 для отождествляющей связи. В отличие от срединного потока, блок выходного потока увеличивает число карт признаков и задерживает сведение между единственным остаточным и сверточным блоками в выходном потоке.

Обратите внимание, что структура остаточного блока выходного потока идентична структуре входного потока, за исключением того, что стиль выходного потока расширяет размерность блока, переходя от 728 к 1024 картам признаков, тогда как входной поток не расширяет размерность.

Теперь перейдем к сверточному блоку выходного потока, который следует за остаточным блоком и показан на рис. 7.16. Этот блок состоит из двух разделяемых по глубине сверток размером 3×3 , каждая из которых выполняет расширение размерности. Это расширение увеличивает число карт признаков соответственно до 1156 и 2048, что завершает отложенную прогрессию увеличения окончательного числа карт признаков перед бутылочным слоем.

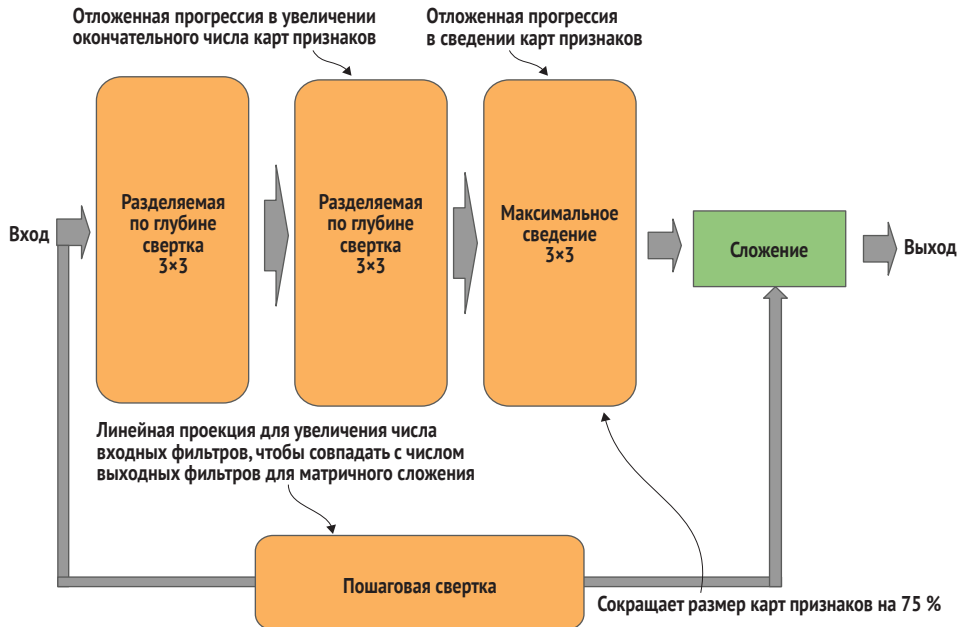


Рис. 7.15 Остаточный блок выходного потока архитектуры Хсептион с линейно-проекционной аббревиатурой задерживает прогрессию увеличения окончательного числа карт признаков и сведение



Рис. 7.16 Сверточный блок выходного потока архитектуры Хсептион завершает отложенную прогрессию числа окончательных карт признаков

Последней группой в выходном потоке является классификатор, состоящий из слоя `GlobalAveragePooling2D`, который сводит и разглаживает окончательные карты признаков в 1-мерный вектор, за кото-

рым следует плотный (Dense) слой с активацией softmax для классифицирования.

7.2.5 Свертка, разделяемая по глубине

Как и было обещано, мы наконец-то добрались до сути разделяемой по глубине свертки в архитектуре Xception. С момента их внедрения разделяемые вглубь свертки находят широкое применение в сверточных нейронных сетях из-за их способности быть менее дорогостоящими в вычислительном отношении при сохранении представительной мощности. Первоначально предложенные в 2014 году Лораном Сифре и Стефаном Маллатом во время работы в Google Brain (Laurent Sifre, Stephane Mallat, <https://arxiv.org/abs/1403.1687>), с тех пор разделяемые по глубине свертки изучались и принимались в различных передовых моделях, включая Xception, MobileNet и ShuffleNet.

Проще говоря, разделяемая по глубине свертка делит 2-мерное ядро на два 2-мерных ядра; первое является сверткой вглубь, а второе – точечной сверткой. В целях полного понимания сначала необходимо понять две взаимосвязанные концепции: свертку вглубь и точечную свертку, из которых строится свертка по глубине.

7.2.6 Свертка вглубь

В свертке вглубь ядро разбивается на одно ядро размером $H \times W \times 1$, по одному на канал, причем каждое ядро работает на одном канале, а не на всех каналах. При такой компоновке межканальные взаимосвязи отстыкованы от пространственных взаимосвязей. Как предположил Шолле, полная отстыковка пространственной и канальной сверток приводит к меньшему числу операций `matmul` и точности, сопоставимой с точностью моделей без отстыковки и нормальной сверткой, а также моделей с частичной отстыковкой и пространственно разделяемой сверткой.

Таким образом, в примере RGB с ядром 3×3 , показанном на рис. 7.17, свертка вглубь будет состоять из трех ядер $3 \times 3 \times 1$. Число операций умножения при перемещении ядра является таким же, как и при нормальной свертке (например, 27 для 3×3 на трех каналах). Однако на выходе получается карта признаков глубиной D , а не 2-мерная карта признаков (`depth=1`).

7.2.7 Точечная свертка

Данные на выходе из свертки вглубь затем передаются на вход в *точечную свертку*, которая образует разделяемую по глубине свертку. Точечная свертка выполняет отстыкованную пространственную свертку. Точечная свертка комбинирует выходы из свертки вглубь и увеличивает число карт признаков в соответствии с указанным

числом фильтров (карт признаков). Указанная комбинация выводит такое же число карт признаков, что и нормальная или разделяемая свертка (89), но с меньшим числом операций матричного умножения (сокращение на 83 %).

Точечная свертка, показанная на рис. 7.18, имеет размер $1 \times 1 \times D$ (число каналов). Она перебирает каждый пиксел в цикле, производя карту признаков $N \times M \times 1$, которая заменяет карту признаков $N \times M \times D$.

По каждому каналу перемещается отдельное ядро размером $3 \times 3 \times 1$




Рис. 7.17 В этой свертке вглубь ядро разбивается на отдельные ядра размером $H \times W \times 1$

Ядро размером 1×1 перемещается по каждому каналу



Рис. 7.18 Точечная свертка

В точечной свертке мы используем ядра $1 \times 1 \times D$, по одному для каждого выхода. Как и в предыдущем примере на рис. 7.17, если мы выводим 256 фильтров (карт признаков), то будем использовать 256 ядер $1 \times 1 \times D$.

В примере RGB с использованием ядра $3 \times 3 \times 3$ для свертки вглубь на рис. 7.17 у нас 27 операций умножения при каждом перемещении ядра. За этим следует $1 \times 1 \times 3 \times 256$ (где 256 – число выходных фильтров), то есть 768. Суммарное число операций умножения составит 795 вместо 6912 для нормальной свертки и 4608 для пространственно разделяемой свертки.

В архитектуре Xception пространственно разделяемые свертки в модуле Inception заменены сверткой, разделяемой по глубине, что снижает вычислительную сложность (число операций умножения)

на 83 %. Полное представление исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для Xception находится в репозитории на GitHub (<http://mng.bz/5WzB>).

7.3 SE-Net: сдавливание и возбуждение

Теперь мы обратимся к еще одному альтернативному шаблону связности, шаблону сдавливания-возбуждения-масштабирования, или SE-Net, который можно добавлять в существующие остаточные сети для повышения точности, привнося всего несколько параметров.

Представляя указанный шаблон в статье «Сети сдавливания и возбуждения» (Squeeze-and-Excitation Networks, Jie Hu et al., <https://arxiv.org/abs/1709.01507>), Цзе Ху и соавт. объяснили, что предыдущие усовершенствования моделей были сосредоточены на пространственных взаимосвязях между сверточными слоями. Поэтому они решили пойти другим путем и исследовать новую конструкцию сети, основанную на взаимосвязи между каналами. Их идея заключалась в том, что рекалибровка признаков может использовать глобальную информацию, чтобы селективно акцентировать важные признаки и деакцентировать менее важные признаки.

В целях обеспечения возможности селективно акцентировать признаки авторы разработали концепцию добавления связи сдавливания-возбуждения (SE) внутри остаточного блока. Этот блок проходит между выходом из сверточного слоя (или слоев) и операцией матричного сложения с отождествляющей связью. Эта концепция выиграла конкурс ILSVRC 2017 года на наборе данных ImageNet.

Их абляционное исследование показало несколько преимуществ подхода SE-Net, в том числе следующие:

- может добавляться в существующие передовые архитектуры, такие как ResNet, ResNeXt и Inception;
- добавляет минимальный рост в параметрах при одновременном достижении более высоких результатов точности. Например:
 - частота ошибок в топ-5 ImageNet составила 7.48 % для ResNet50 и 6.62 % для SE-ResNet50;
 - частота ошибок в топ-5 ImageNet составила 5.9 % для ResNeXt50 и 5.49 % для SE-ResNeXt50;
 - частота ошибок в топ-5 ImageNet составила 7.89 % для Inception и 7.14 % для SE-Inception.

7.3.1 Архитектура SE-Net

Показанная на рис. 7.19 архитектура SE-Net состоит из существующей остаточной сети, которая затем переоборудуется за счет вставки связи SE в остаточные блоки. Переоборудованные архитектуры ResNet и ResNeXt называются соответственно SE-ResNet и SE-ResNeXt.

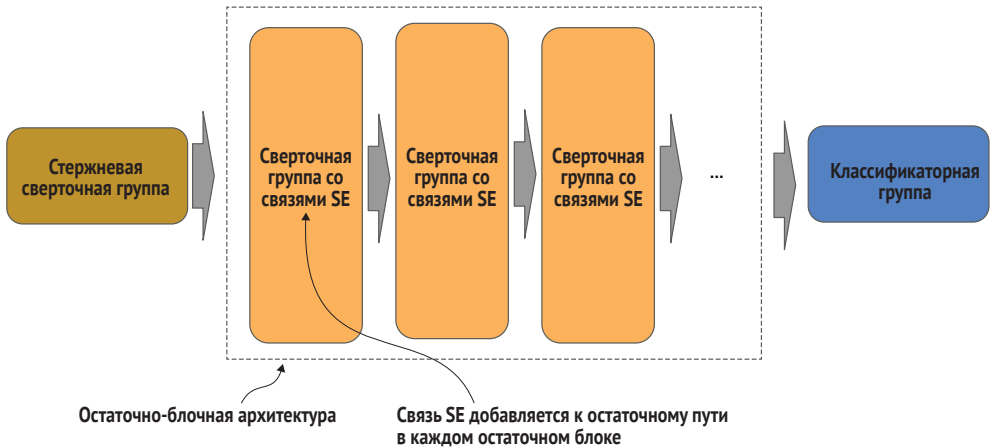


Рис. 7.19 Макроархитектура SE-Net, показывающая добавление связи SE к каждому остаточному блоку

7.3.2 Группа и блок архитектуры SE-Net

Если мы разберем макроархитектуру, то обнаружим, что каждая сверточная группа на рис. 7.19 состоит из одного или нескольких остаточных блоков, составляющих остаточную группу. Каждый остаточный блок имеет связь SE. Крупный план этой остаточной группы показан на рис. 7.20.

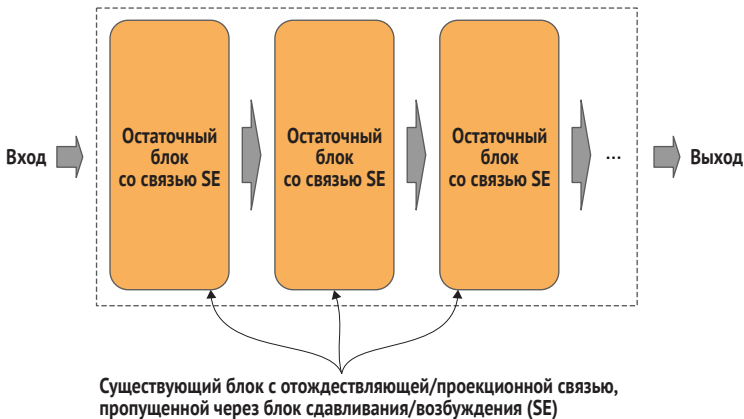


Рис. 7.20 В каждый остаточный блок остаточной группы вставлена связь SE

Теперь давайте разберем остаточную группу. На рис. 7.21 показано, как связь SE вставляется в остаточный блок между выходом из сверточного слоя (слоев) и операцией матричного сложения.

Следующий ниже исходный код является примером имплементации добавления связи SE в остаточный блок ResNet. В конце блока вызов функции `squeeze_excite_link()` вставляется между выхо-

дом из $B(3,3)$ и операций матричного сложения ($Add()$). В функции `squeeze_excite_link()` мы имплементируем ссылку SE (подробно описано в следующем подразделе).

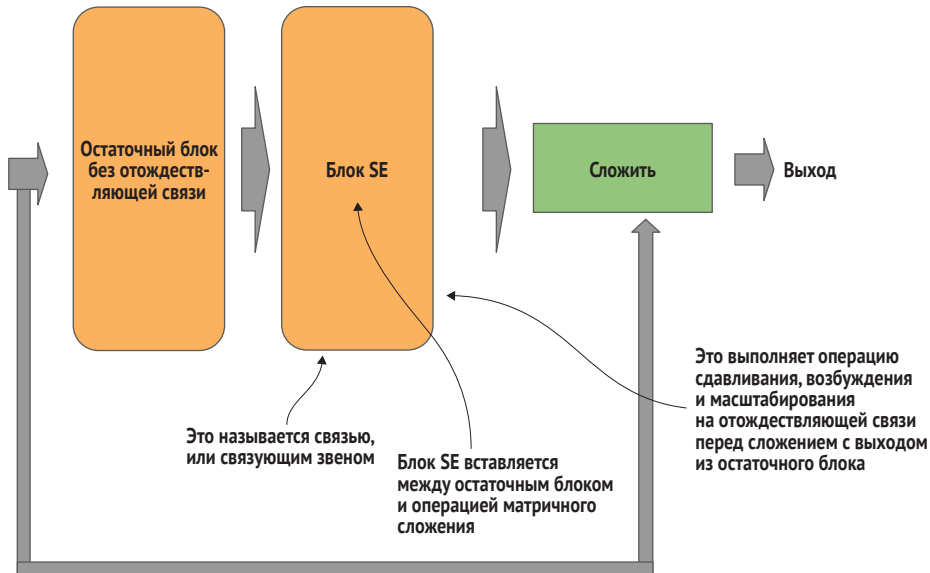


Рис. 7.21 Остаточный блок, показывающий, как связь SE вставляется между остаточным путем и операцией матричного сложения (обозначается как Сложить) для отождествляющей связи

Параметр `ratio` представляет собой величину (отношение) редукции размерности на операции сжатия на входе перед последующим восстановлением размерности с помощью операции возбуждения.

```
def identity_block(x, n_filters, ratio=16):
    """ Создать бутылочный остаточный блок с отождествляющей связью
        x : вход в блок
        n_filters: число фильтров
        ratio : объем сокращения фильтров во время сжатия
    """
    shortcut = x

    x = Conv2D(n_filters, (1, 1), strides=(1, 1))(x)
    x = BatchNormalization()(x)
    x = ReLU()(x)

    x = Conv2D(n_filters, (3, 3), strides=(1, 1), padding="same")(x)
    x = BatchNormalization()(x)
    x = ReLU()(x)

    x = Conv2D(n_filters * 4, (1, 1), strides=(1, 1))(x)
    x = BatchNormalization()(x)
```

Свертка 1×1 для редукции размерности

Свертка 3×3 для бутылочного слоя

Свертка 1×1 увеличивает фильтры в 4 раза для восстановления размерности


```

x = squeeze_excite_link(x, ratio)
x = Add()( [shortcut, x] )
x = ReLU()(x)
return x

```

← Пропускает выход через связь сдавливания и возбуждения
 ← Складывает отождествляющую связь (вход) с выходом из остаточного блока

7.3.3 Связь SE

Теперь давайте рассмотрим связь SE (рис. 7.22) подробно. Указанная связь состоит из трех слоев. Первые два слоя выполняют операцию сдавливания. Глобальное среднее сведение используется для сокращения каждой входной карты признаков (канала) до одного значения, выводя 1-мерный вектор размера C (каналы), который затем реформируется в 1×1 -пиксельную 2-мерную матрицу размером C (каналов). Затем плотный слой еще больше сокращает выход на коэффициент редукции r , в результате чего получается 1×1 -пиксельная 2-мерная матрица размером C/r (каналов).

Сдавленный выход затем передается в третий слой, который выполняет возбуждение путем восстановления числа каналов (C), введенных в связь. Обратите внимание, что это сопоставимо с использованием линейно-проекционной свертки 1×1 , но вместо этого выполняется с плотным слоем.

Заключительным шагом является операция масштабирования, которая состоит из отождествляющей связи из входа, где вектор $1 \times 1 \times C$ из операции сдавливания-возбуждения подвергается операции матричного умножения с входом ($H \times W \times C$). После операции масштабирования выходная размерность (число и размер карт признаков) восстанавливается до изначальной входной размерности (масштаба).

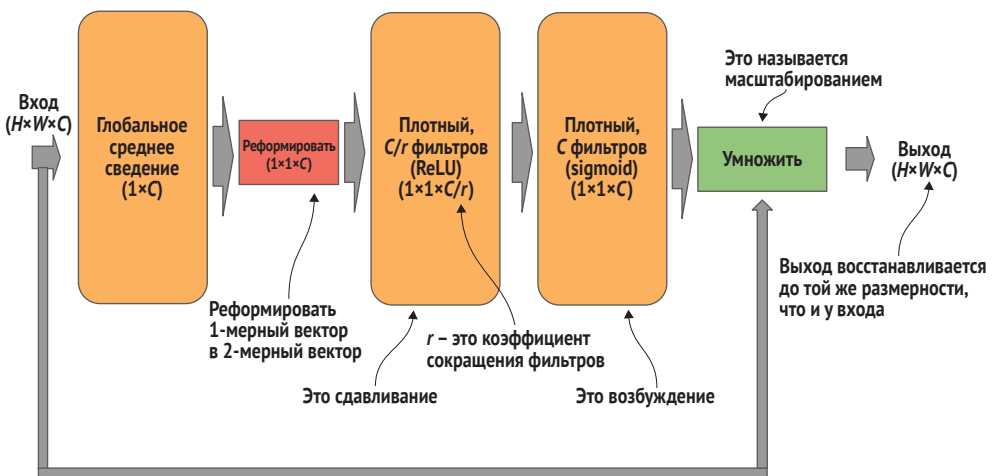


Рис. 7.22 Блок сдавливания-возбуждения, показывающий операции сдавливания, возбуждения, а затем операцию масштабирования

Теперь давайте рассмотрим пример имплементации связи SE, состоящей из операций сдавливания, возбуждения и масштабирования. Обратите внимание на операцию реформирования (Reshape) после GlobalAveragePooling2D, чтобы конвертировать сведенный 1-мерный вектор в 1×1 пиксельный 2-мерный вектор для последующих двух плотных слоев, которые выполняют соответственно операции сдавливания и возбуждения. Матрица $1 \times 1 \times C$, полученная в результате возбуждения, затем путем матричного умножения, умножается на вход (shortcut) для операции масштабирования:

Операция сдавливания для редукции размерности с использованием глобального среднего сведения, которое выдает 1-мерный вектор

```
def squeeze_excite_link(x, ratio=16):
    """ Создать связь сдавливания и возбуждения
        x : вход в связь
        ratio : объем сокращения фильтров во время сдавливания
    """
    shortcut = x
    n_filters = x.shape[-1]
    x = GlobalAveragePooling2D()(x)
    x = Reshape((1, 1, n_filters))(x)
    x = Dense(n_filters // ratio, activation='relu')(x)
    x = Dense(n_filters, activation='sigmoid')(x)
    x = Multiply()([shortcut, x])
    return x
```

Получает число карт признаков (фильтров) во входе в связь SE

Реформирует выход в карты признаков 1×1 ($1 \times 1 \times C$)

Сокращает число фильтров ($1 \times 1 \times C/r$) на коэффициент редукции

Операция масштабирования, умножение выхода из сдавливания/возбуждения на вход ($W \times H \times C$)

Операция возбуждения для восстановления размерности путем восстановления числа фильтров ($1 \times 1 \times C$)

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для SE-Net находится в репозитории на GitHub (<http://mng.bz/vea7>).

Резюме

- Реиспользование признаков в DenseNet заменяет матричное сложение конкатенацией карт признаков входа с выходом из остаточного блока. Эта классификация повышает точность по сравнению с существующими передовыми (SOTA) моделями.
- Использование свертки 1×1 в DenseNet для усвоения – это самый лучший способ отбора из карт признаков с повышенной и пониженной частотой выборки для конкретного набора данных.
- Дальнейшее разложение пространственно разделяемой свертки в свертку, разделяемую по глубине, в Xception еще больше снижает вычислительные затраты при сохранении эквивалентности представления.
- Добавление шаблона сдавливания-возбуждения-масштабирования в SE-Net к существующим остаточным сетям повышает точность при добавлении всего нескольких параметров.

Мобильные сверточные нейронные сети

Эта глава охватывает следующие ниже темы:

- понимание принципов конструирования мобильных сверточных сетей и уникальных требований к ним;
- инспектирование шаблонов конструирования для MobileNet v1 и v2, SqueezeNet и ShuffleNet;
- примеры кодирования этих моделей с использованием шаблона процедурного конструирования;
- строительство более компактных моделей путем квантизации моделей и последующего их исполнения с помощью TensorFlow Lite (TF Lite).

Вы изучили несколько ключевых шаблонов конструирования крупных моделей без ограничений памяти. Теперь давайте обратимся к шаблонам конструирования, таким как популярное приложение FaceApp от Facebook, оптимизированное под устройства с ограниченным объемом памяти, такие как мобильные телефоны и устройства интернета вещей.

В отличие от своих эквивалентов для ПК или облачных вычислений, компактные модели имеют особую проблему: они должны оперировать на существенно меньших объемах памяти и, следовательно, не могут извлекать выгоду от использования сверхъёмкости для достижения высокой точности. Для того чтобы вписываться в эти ограниченные объемы памяти, модели должны иметь существенно меньше параметров для предсказательного вывода, или предсказания. Архитектура компактных моделей основана на компромиссе

между точностью и задержкой. Чем больше памяти устройства занимает модель, тем выше точность, но тем больше задержка отклика.

В ранних сверточных передовых (SOTA) мобильных моделях исследователи нашли способы решать этот компромисс с помощью методов, которые существенно снижали параметры и сложность вычислений при сохранении минимальной потери точности. Эти методы основывались на дальнейшей переработке сверток, таких как разделяемая по глубине свертка (MobileNet) и точечные групповые свертки (ShuffleNet). Эти методы переработки предоставили средства для повышения точности, которая в противном случае утрачивалась бы более экстремальными методами переработки.

В данной главе представлены два из таких подходов к переработке, используемых в двух разных моделях: MobileNet и SqueezeNet. Мы также рассмотрим еще один новый подход к устройствам с ограниченной памятью в третьей модели, ShuffleNet. Мы закончим главу разведывательным анализом других стратегий дальнейшего сокращения объема памяти, таких как сжатие параметров и квантизация, чтобы делать модели компактнее.

Прежде чем начнем рассматривать особенности трех моделей, давайте кратко сравним методы, которые в них используются для работы с лимитированной памятью. Исследователи MobileNet развели стратегии утончения модели для адаптации к различным объемам памяти и требованиям к задержке, а также влияние утончения на точность.

Исследователи SqueezeNet предложили блочный шаблон, именуемый *огневым модулем* (fire module), который будет поддерживать точность после сокращения размера модели на 90 %. В огневом модуле используется глубокое сжатие. Этот метод сжатия размера нейронной сети был заявлен в статье «Глубокое сжатие» Сонг Хана и соавт. (Deep Compression, Song Han et al., <https://arxiv.org/abs/1510.00149>), представленной на Международной конференции по автоматическому усвоению представлений 2015 года (ICLR).

Тем временем исследователи модели ShuffleNet сосредоточились на увеличении представительной мощности моделей, развернутых на вычислительных устройствах с чрезвычайно низким энергопотреблением (например, от 10 до 150 Мфлоп). Они предложили двойной подход: перетасовку каналов внутри высокопереработанной группы наряду с точечной сверткой.

Теперь мы можем углубиться в детали каждого из них.

8.1 MobileNet v1

MobileNet v1 – это архитектура, представленная компанией Google в 2017 году для производства малых сетей, которые могут укладываться в мобильные устройства и устройства интернета вещей, со-

храня при этом точность, близкую к их более крупным сетевым аналогам. Архитектура MobileNet v1, описанная в статье «MobileNets» Эндрю Г. Говарда и соавт. (<https://arxiv.org/abs/1704.04861>), заменяет нормальные свертки разделяемыми по глубине свертками, служащими для дальнейшего снижения вычислительной сложности. (Как вы помните, мы рассмотрели теорию, лежащую в основе переработки обычных свертки в разделяемые по глубине свертки, когда разбирали модель Xception в главе 7.) Давайте посмотрим, как этот подход был применен в архитектуре MobileNet к компактной модели.

8.1.1 Архитектура

Архитектура MobileNet v1 включала в себя несколько принципов конструирования устройств с ограниченной памятью:

- стержневая сверточная группа ввела дополнительный параметр, именуемый *множителем разрешающей способности*, для более агрессивного сокращения *размера* карт признаков, подаваемых в ученический компонент (она обозначена буквой A на рис. 8.1);
- ученический компонент аналогичным образом добавил параметр *множитель ширины* для более агрессивного сокращения *числа* карт признаков в ученическом компоненте (B);
- в модели используются свертки вглубь (как в Xception) с целью сокращения вычислительной сложности при сохранении эквивалентности представления (C);

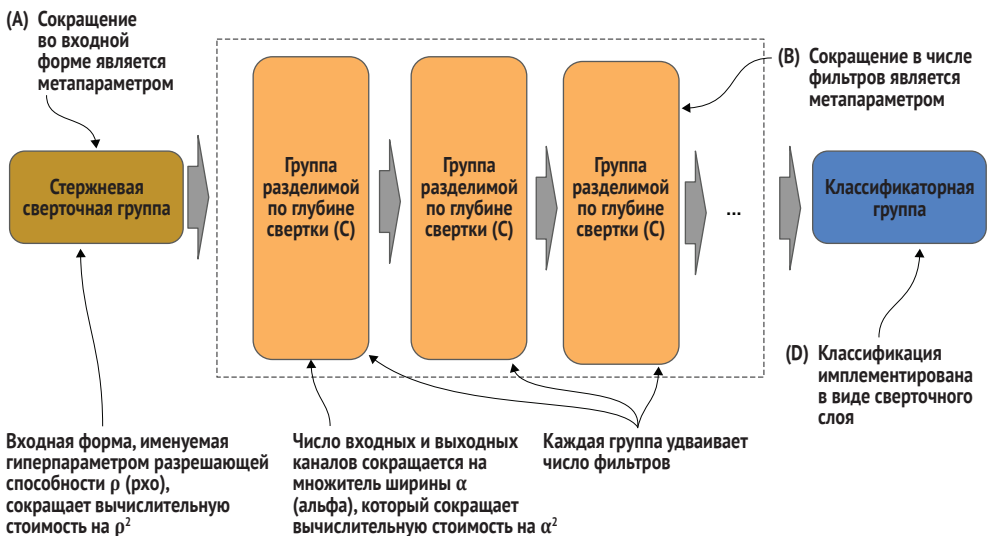


Рис. 8.1 В макроархитектуре MobileNet v1 используются метапараметры в стержне и ученике (A и B), а также свертки вглубь в ученике (C) и сверточный слой вместо плотного слоя в классификаторе (D)

- в классификаторном компоненте вместо плотного слоя используется сверточный слой с целью окончательного классифицирования (D).

Эти нововведения, имплементированные в макроархитектуре, можно увидеть на рис. 8.1, где буквы А, В, С и D обозначают соответствующую функциональность.

В отличие от моделей, которые мы рассматривали до сих пор, модели MobileNet категоризируются не по числу слоев, а по разрешающей способности входа. Например, MobileNet-224 имеет на входе (224, 224, 3). Сверточные группы следуют традиции удвоения числа фильтров из предыдущей группы.

Сначала давайте рассмотрим два новых гиперпараметра, множитель ширины и множитель разрешающей способности, чтобы понять, как и где они помогают утончать сеть. Ниже мы пошагово рассмотрим стержневой, ученический и классификаторный компоненты.

8.1.2 Множитель ширины

Первым введенным гиперпараметром был множитель ширины α (альфа), который равномерно в каждом слое делал сеть тоньше. Давайте кратко рассмотрим плюсы и минусы утончения сети.

Мы знаем, что, делая сеть тоньше, мы сокращаем число параметров между слоями и экспоненциально сокращаем число операций `matmul`. Используя плотные слои, например если до утончения выход из одного плотного слоя и соответствующий вход составляют 100 параметров каждый, то у нас будет 10 000 операций матричного умножения (`matmul`). Другими словами, два 100-узловых плотных слоя, полностью соединенных друг с другом, будут иметь 100×100 операций `matmul` в расчете на 1-мерный вектор, который проходит через два слоя.

Теперь давайте сделаем ее тоньше вдвое. Это 50 выходных параметров и 50 входных параметров. Сейчас мы сократили число операций `matmul` до 2500. Результатом будет сокращение объема памяти на 50 % и сокращение вычислений (задержка) на 75 %. Недостатком является то, что мы еще больше устраняем сверхъемкость, необходимую для точности, и нам потребуется разведать другие стратегии, чтобы это компенсировать.

В каждом слое число входных каналов равно αM , а число выходных каналов равно αN , где M и N – это число каналов (карт признаков) неутонченной модели MobileNet. Теперь давайте посмотрим на расчеты сокращения параметров путем утончения сетевых слоев. Значение α (альфа) находится в интервале от 0 до 1 и будет сокращать вычислительную сложность модели MobileNet на α^2 (число параметров). Значение $\alpha < 1$ называется *редуцированной MobileNet*. Как правило, значения составляют 0.25 (6 % неутонченной), 0.50 (25 %) и 0.75 (56 %). Давайте продолжим и выполним вычисления. Если коэффи-

коэффициент α равен 0.25, то результирующая сложность равна 0.25×0.25 , что в итоге дает 0.0625.

В представленных в статье результатах тестов неутонченная модель MobileNet-224 имела точность 70.6 % на наборе данных ImageNet с 4.2 млн параметров и 569 млн операций матричного умножения и сложения, тогда как 0.25-я (множитель ширины) модель MobileNet-224 имела точность 50.6 % с 0.5 млн параметров и 41 млн операций матричного умножения и сложения. Эти результаты показывают, что потеря сверхъёмкости в результате агрессивного утончения не была эффективно компенсирована модельной конструкцией. Поэтому исследователи обратились к сокращению разрешающей способности, что оказалось эффективнее в поддержании точности.

8.1.3 Множитель разрешающей способности

Вторым введенным гиперпараметром был *множитель разрешающей способности* ρ (ρ_{xo}), который сокращает входную форму и, следовательно, размеры карт признаков в каждом слое.

Когда мы сокращаем входную разрешающую способность без изменения стержневого компонента, размер карт признаков, входящих в учебный компонент, соответственно сокращается. Например, если высота и ширина входного изображения сокращены наполовину, то число входных пикселей сокращается на 75 %. Если мы поддерживаем те же фильтры грубого уровня и число фильтров, то выводимые карты признаков сократятся на 75 %. Поскольку карты признаков сокращены, то это приведет к нижестоящему эффекту сокращения числа параметров в расчете на свертку (размера модели) и числа операций matmul (задержки). Обратите внимание, что это контрастирует с утончением ширины, которое сокращало число карт признаков при сохранении их размера.

Недостатком является то, что если мы будем сокращать слишком агрессивно, то размер карт признаков к тому времени, когда мы доберемся до бутылочного горлышка, может составить 1×1 пиксел и мы, по сути, потеряем пространственные взаимосвязи. Мы могли бы это компенсировать, сократив число промежуточных слоев, чтобы карты признаков были больше, чем 1×1 , но тогда мы удаляем больше сверхъёмкости, необходимой для повышения точности.

В представленных в статье результатах тестов модель MobileNet-224 с разрешающей способностью 0.25 (множитель разрешающей способности) имела точность 64.4 % с 4.2 млн параметров и 186 млн операций матричного умножения и сложения. Давайте продолжим и выполним вычисления, учитывая, что значение ρ (ρ_{xo}) находится в интервале между 0 и 1, и сократим вычислительную сложность модели MobileNet на ρ^2 . Если коэффициент ρ равен 0.25, то результирующая сложность равна 0.25×0.25 , что в итоге дает 0.0625.

Ниже приведена скелетная заготовка модели MobileNet-224. Обратите внимание на использование параметров множителя ширины α и разрешающей способности ρ :

```
def stem(inputs, alpha):
    """ Построить стержневую группу
        inputs : входной тензор
        alpha : множитель ширины
    """
    return outputs

def learner(inputs, alpha):
    """ Построить учебническую группу
        inputs : данные на входе в ученика
        alpha : множитель ширины
    """
    return outputs

def classifier(inputs, alpha, dropout, n_classes):
    """ Построить классификаторную группу
        inputs : данные на входе в классификатор
        alpha : множитель ширины
        dropout: процент отсева
        n_classes: число выходных классов
    """
    return outputs

inputs = Input((224*rho, 224*rho, 3))
outputs = stem(inputs, alpha)
outputs = learner(outputs, alpha)
outputs = classifier(outputs, alpha, dropout, n_classes)
model = Model(inputs, outputs)
```

Исходный код удален для краткости

Этот множитель используется во всех слоях модели

Разрешающая способность, используемая только для входного тензора

8.1.4 Стержень

Стержневой компонент состоит из пошаговой свертки 3×3 для сведения признаков, за которой следует один разделяемый по глубине блок из 64 фильтров. Число фильтров как в пошаговой свертке, так и в блоке по глубине сокращается дальше с помощью гиперпараметра α (альфа). Сокращение входного размера на гиперпараметр ρ (ρ) выполняется не в модели, а выше в функции предобработки входных данных.

Давайте посмотрим, как это отличалось от традиционного в то время стержня для крупной модели. По обыкновению первый сверточный слой начинается с грубой свертки 7×7 , или 5×5 , или разложенной стопки из двух сверток 3×3 с 64 фильтрами. Грубая свертка была пошаговой с целью сокращения размера карт признаков, а затем следовал слой максимального сведения с целью еще одного сокращения размера карт признаков.

В стержне MobileNet v1 сохраняется традиция использовать 64 фильтра и стопки из двух сверток 3×3 , но с тремя существенными изменениями:

- первая свертка выдает половину (32) числа карт признаков, как вторая. Она действует как бутылочное горлышко, сокращая вычислительную сложность в двойной стопке 3×3 ;
- вторая свертка заменяется разделяемой по глубине сверткой, что еще больше сокращает вычислительную сложность в стержне;
- без максимального сведения существует только одно сокращение размера карт признаков с помощью первой пошаговой свертки.

Здесь компромисс заключается в том, что размеры карт признаков остаются крупнее – вдвое больше $H \times W$. За счет этого компенсируется потеря представления из-за агрессивного сокращения вычислительной сложности в первом выделении признаков грубого уровня.

На рис. 8.2 показан стержневой компонент, который состоит из стопки из двух сверток 3×3 . Первая – это нормальная свертка, в которой есть сведение (пошаговое) признаков.

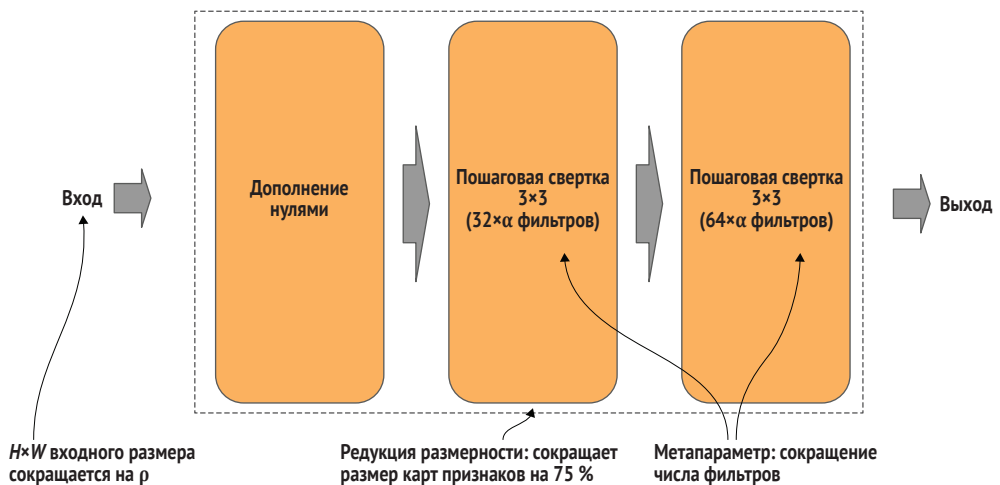


Рис. 8.2 Стержневая группа модели MobileNet делает сеть тоньше в стопке сверток 3×3

Вторая – это (бесшаговая) свертка вглубь, которая поддерживает размер карт признаков. В пошаговой свертке 3×3 дополнение не использовалось. В целях поддержания сокращения карт признаков на 75 % ($0.5H \times 0.5W$) ко входу перед сверткой добавляется дополнение нулями. Обратите внимание на использование метапараметра ρ на входном размере для сокращения разрешающей способности и α на двойной стопке сверток 3×3 для утончения сети.

Ниже приведен пример имплементации стержневого компонента. Как вы видите, постактивационная пакетная нормализация (Conv-BN-RE) используется для сверточных слоев, поэтому модель не имела

выгод от использования преактивационной пакетной нормализации, которая, как было установлено, повышает точность с 0.5 до 2 %:

```
def stem(inputs, alpha):
    """ Построить стержневую группу
        inputs : входной тензор
        alpha : множитель ширины
    """
    x = ZeroPadding2D(padding=((0, 1), (0, 1)))(inputs)
    x = Conv2D(32 * alpha, (3, 3), strides=(2, 2), padding='valid')(x)
    x = BatchNormalization()(x)
    x = ReLU(6.0)(x)
    x = depthwise_block(x, 64, alpha, (1, 1))
    return x
```

Сверточный блок с дополнением входных карт признаков нулями

Разделяемый по глубине сверточный блок

Обратите внимание, что ReLU в этом примере принимает необязательный параметр со значением 6.0. Это аргумент `max_value` для ReLU, значение которого по умолчанию равно None. Его предназначение – обрезать любое значение выше `max_value`. Таким образом, в предыдущих примерах все выходные данные будут находиться в диапазоне от 0 до 6.0. На практике в мобильных сетях принято обрезать выходы из ReLU, если позже веса будут квантироваться.

Квантирование в данном контексте – это вычисления с использованием представления с младшими битами; детали этого процесса я объясню в разделе 8.5.1. Было обнаружено, что квантированные модели обеспечивают более высокую точность, когда выход из ReLU имеет ограниченный диапазон. На практике принято устанавливать его равным 6.0.

Давайте кратко обсудим причины выбора значения 6. Эта концепция была представлена в статье Алекса Крижевского 2010 года «Сверточные глубокие сети уверенности на наборе данных CIFAR-10» (Convolutional Deep Belief Networks on CIFAR-10, Alex Krizhevsky, www.cs.utoronto.ca/~kriz/conv-cifar10-aug2010.pdf). Крижевский предложил это число как решение проблемы взрывающихся градиентов в более глубоких слоях.

Когда выход из активации становился очень крупным, он мог доминировать над выходами из окружающих активаций. Как следствие эта область сети будет демонстрировать симметрию, что означает, что она будет сокращаться, как если бы существовал только один узел. Экспериментируя, Крижевский пришел к выводу, что значение 6 является наилучшим.

Вспомните, это было до того, как мы узнали о выгодах от пакетной нормализации, которая будет введена только в 2015 году. При пакетной нормализации активации будут сплющиваться на каждой последующей глубине, поэтому необходимость в отсечении отпадает.

Идея обрезания ReLU вернулась, когда была введена квантизация. Одним словом, когда веса квантируются, мы уменьшаем число

битов, представляющих значение. Если бы мы соотнесли веса, скажем, с 8-битовым целочисленным диапазоном, то нам пришлось бы сгруппировать весь выходной диапазон на 256 «корзин», основываясь на фактическом распределении выходных значений. Чем длиннее диапазон, тем растянуто тоньше соотнесение значений (с плавающей точкой) с корзинами, что делает каждую корзину менее различимой.

Здесь теория заключается в том, что значения, которые имели бы 98, 99 и 99.5%-ную уверенность, по существу одинаковы, а более низкие ее значения были бы различимее – то есть выход имеет 70%-ную уверенность. Но при обрезании мы трактуем все, что выше 6, как по существу 100 %, и учитываем только распределение между 0 и 6, и эти значения содержательнее для выхода.

8.1.5 Ученик

Ученический компонент в модели MobileNet-224 состоит из четырех групп, и каждая группа состоит из двух или более сверточных блоков. Каждая группа будет удваивать число фильтров по сравнению с предыдущей группой, и первый блок в каждой группе использует пошаговую свертку (сведение признаков) для сокращения размеров карт признаков на 75 %.

Строительство группы модели MobileNet следует тем же принципам, что и ее крупные сетевые группы. Обе, как правило, имеют следующее:

- 1 прогрессия в числе фильтров в расчете на группу, например удвоение числа фильтров;
- 2 сокращение в размерах выдаваемых карт признаков путем пошаговой свертки либо путем отложенного максимального сведения.

На рис. 8.3 видно, что в группе модели MobileNet используется пошаговая свертка для первого блока, чтобы сократить карту признаков (принцип 2). Хотя это не показано на диаграмме, каждая группа в ученике удваивает число фильтров (принцип 1), начиная со 128.

Рисунок 8.4 показывает сверточный блок по глубине в ученической группе крупным планом. В версии v1 авторы модели использовали конструкцию сверточного блока вместо конструкции остаточного блока; отождествляющая связь отсутствует. Каждый блок, по существу, представляет собой одну разделяемую по глубине свертку, построенную в виде двух отдельных сверточных слоев. Первый слой представляет собой свертку вглубь 3×3 , за которой следует точечная свертка 1×1 . В сочетании они образуют разделяемую по глубине свертку. Число фильтров, которое соответствует числу карт признаков, может быть сокращено еще больше с целью утончения сети с помощью метапараметра α .

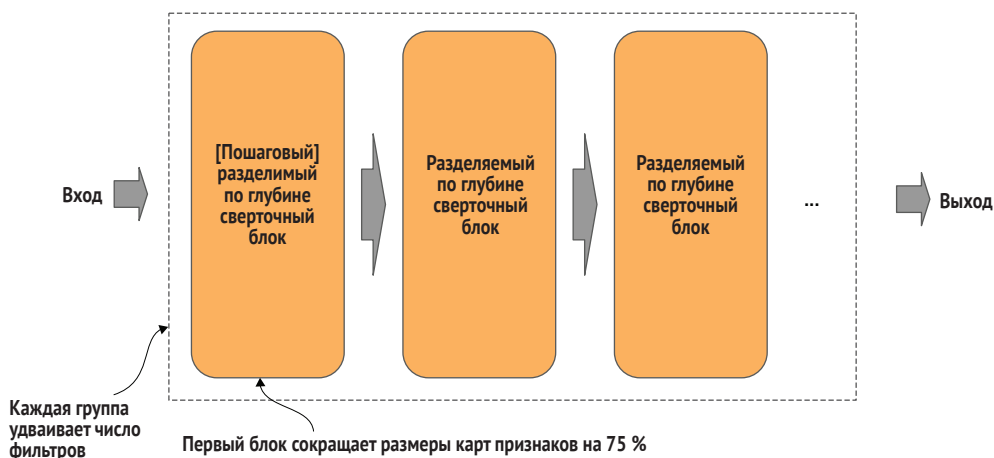


Рис. 8.3 В учебном компоненте модели MobileNet v1 каждая группа представляет собой последовательность сверточных блоков по глубине

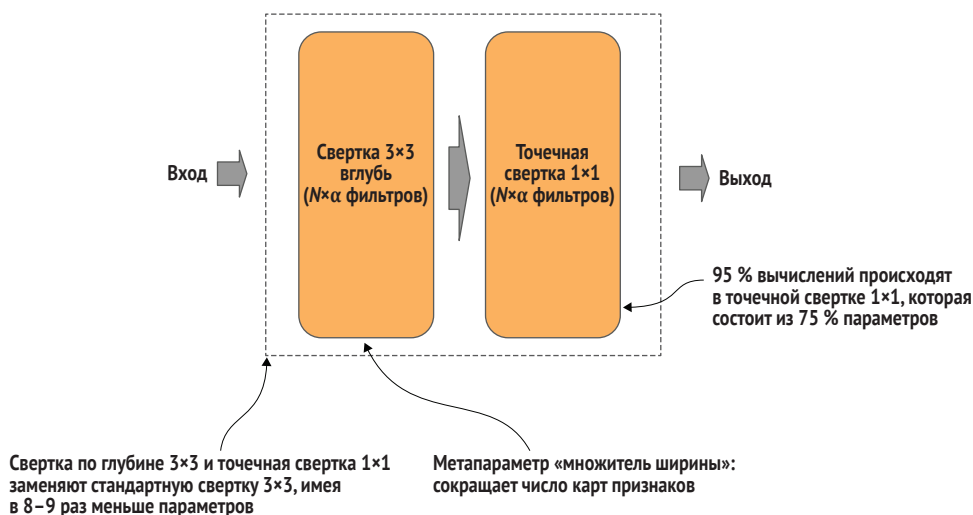


Рис. 8.4 Сверточный блок модели MobileNet v1

Далее приведен пример имплементации разделяемого по глубине сверточного блока. На первом шаге вычисляется число сокращенных фильтров (filters), чтобы сделать сеть тоньше после применения множителя ширины α . Для первого блока в группе размеры карт признаков сокращаются (сведение признаков) с использованием пошаговой свертки ($\text{strides}=(2, 2)$). Это соответствует упомянутому ранее конструктивному принципу 2 сверточных групп, где первый блок в группе обычно редуцирует размерность входных карт признаков.

```
def depthwise_block(x, n_filters, alpha, strides):
    """ Построить разделяемый по глубине сверточный блок
        x : данные на входе в блок
        n_filters : число признаков
        alpha : множитель ширины карт признаков
        strides : сдвиговые шаги
    """
    filters = int(n_filters * alpha)

    if strides == (2, 2):
        x = ZeroPadding2D(padding=((0, 1), (0, 1)))(x)
        padding = 'valid'
    else:
        padding = 'same'

    x = DepthwiseConv2D((3, 3), strides, padding=padding)(x)
    x = BatchNormalization()(x)
    x = ReLU(6.0)(x)

    x = Conv2D(filters, (1, 1), strides=(1, 1), padding='same')(x)
    x = BatchNormalization()(x)
    x = ReLU(6.0)(x)
    return x
```

Применяет фильтр ширины к числу карт признаков

Добавляет дополнения нулями при наличии пошаговой свертки для сочетания с числом фильтров

Свертка вглубь

Точечная свертка

8.1.6 Классификатор

Классификаторный компонент отличался от традиционного классификатора в крупных моделях тем, что на шаге классифицирования вместо плотного слоя использовался сверточный слой. Как и другие классификаторы того времени, чтобы предотвратить запоминание, перед классифицированием он добавлял слой отсева для регуляризации.

На рис. 8.5 видно, что классификаторный компонент содержит слой `GlobalAveragePooling2D` для разглаживания карт признаков и сокращения высокоразмерной кодировки в низкоразмерную кодировку (1 пиксел в расчете на карту признаков). Затем слой `Reshape` реформирует 1-мерный вектор для 2-мерной свертки с использованием софтмаксной активации, в которой число фильтров равно числу классов. Потом идет еще один слой `Reshape`, чтобы реформировать выход обратно в 1-мерный вектор (по одному элементу на класс). Перед 2-мерной сверткой находится слой отсева для регуляризации.

Ниже приведен пример имплементации классификаторного компонента. Первый слой `Reshape` реформирует 1-мерный вектор из слоя `GlobalAveragePooling2D` в 2-мерный вектор размером 1×1 . Второй слой `Reshape` реформирует 2-мерный вывод 1×1 из `Conv2D` в 1-мерный вектор для софтмаксного распределения вероятностей (классифицирования):

```
def classifier(x, alpha, dropout, n_classes):
    """ Построить классификаторную группу
```

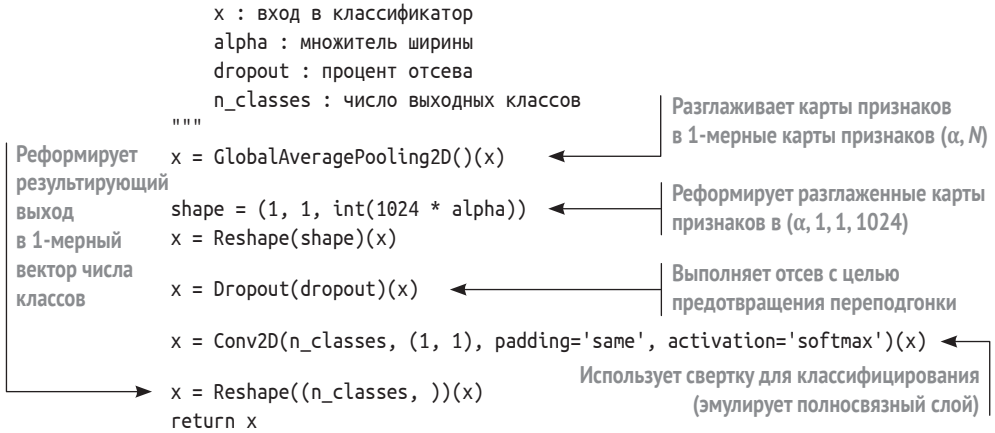


Рис. 8.5 Классификационная группа модели MobileNet v1, в которой для классифицирования используется сверточный слой

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для MobileNet v1 находится в репозитории на GitHub (<http://mng.bz/Q2rG>).

8.2 MobileNet v2

После усовершенствования версии 1 компания Google в 2018 году представила MobileNet v2 в статье «MobileNetV2: инвертированные остатки и линейные бутылочные горлышки» Марка Сэндлера и соавт. (MobileNetV2: Inverted Residuals and Linear Bottlenecks, Mark

Sandler et al., <https://arxiv.org/abs/1801.04381>). Новая архитектура заменяет сверточные блоки инвертированными остаточными блоками с целью повышения производительности. В статье обобщаются преимущества инвертированных остаточных блоков:

- значительное уменьшение числа операций при поддержании той же точности, что и у сверточного блока;
- значительное сокращение объема памяти, необходимого для предсказательного вывода.

8.2.1 Архитектура

Архитектура MobileNet v2 включала в себя несколько принципов конструирования устройств с ограниченной памятью:

- в ней продолжено использование гиперпараметра α (альфа) в качестве множителя ширины, как и в версии v1, с целью утончения сети в стержневом и ученическом компонентах;
- продолжено использование разделяемых по глубине сверток вместо нормальных сверток, как в v1, с целью существенного снижения вычислительной сложности (задержки) при сохранении почти сопоставимой представительной мощности;
- заменено использование сверточных блоков остаточными блоками, что позволяет использовать более глубокие слои с целью обеспечения большей точности;
- представлена новая конструкция остаточных блоков, которую авторы называли инвертированными остаточными блоками;
- заменено использование нелинейных сверток 1×1 линейными свертками 1×1 .

Причина последней модификации с использованием линейных сверток 1×1 , по мнению авторов, была в следующем: «Кроме того, мы считаем, что важно устранить нелинейности в бутылочных горлышках, чтобы поддерживать представительную мощность». В своем абляционном исследовании они сравнили использование нелинейной свертки 1×1 (с ReLU) с линейной сверткой 1×1 (без ReLU) и получили повышение точности на 1 % в топ-1 на ImageNet за счет удаления ReLU.

Авторы описывают свой главный вклад как новый слоевой модуль: инвертированный остаток с линейным бутылочным горлышком. Я подробно описываю инвертированный остаточный блок в разделе 8.2.3.

На рис. 8.6 показана архитектура MobileNet v2. В указанной макроархитектуре ученический компонент состоит из четырех инвертированных остаточных групп, за которыми следует заключительная линейная свертка 1×1 , а значит, активационная функция является линейной. Каждая инвертированная остаточная группа увеличивает число фильтров из предыдущей группы. Число фильтров в группе утончается с помощью метапараметра множителя ширины α (альфа).

Заключительная свертка 1×1 выполняет линейную проекцию, увеличивая окончательное число карт признаков в четыре раза, до 2048.

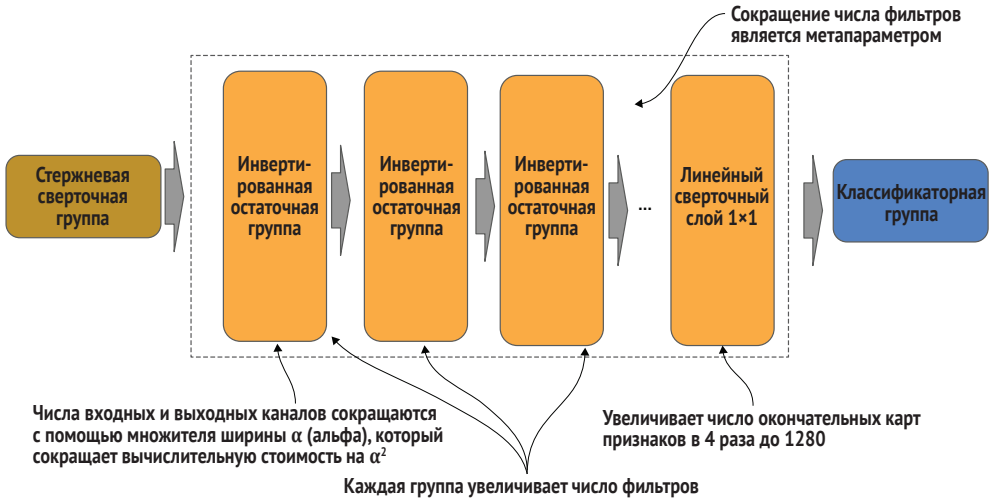


Рис. 8.6 Макроархитектура MobileNet v2

8.2.2 Стержень

Стержневой компонент аналогичен v1, за исключением того, что после начального сверточного слоя 3×3 за ним не следует сверточный блок по глубине, как в v1 (рис. 8.7). В силу этого выделение признаков грубого уровня будет иметь меньшую представительную мощность, чем двойная стопка 3×3 в версии v1. Авторы не указывают причину, почему снижение представительной мощности не повлияло на модель, которая превзошла v1 по точности.

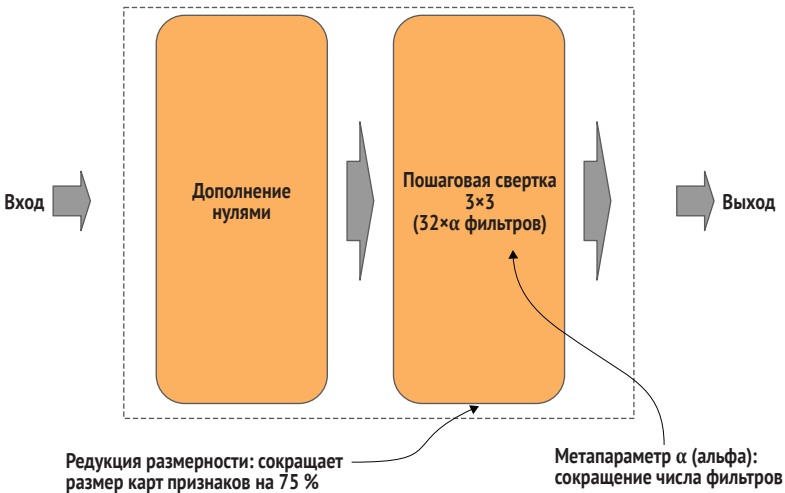


Рис. 8.7 Стержневая группа MobileNet v2

8.2.3 Ученик

Ученический компонент состоит из семи инвертированных остаточных групп, за которыми следует линейная свертка 1×1 . Каждая инвертированная остаточная группа состоит из двух или более инвертированных остаточных блоков. Каждая группа постепенно увеличивает число фильтров, также именуемых *выходными каналами*. Каждая группа начинается с пошагового сверточного слоя, сокращая размер карт признаков (каналов), по мере того как каждая группа поступательно увеличивает число карт признаков.

На рис. 8.8 изображена группа модели MobileNet v2, в которой первый инвертированный остаточный блок удален с целью сокращения размера карт признаков, чтобы компенсировать поступательное увеличение числа карт признаков в группе. Как отмечено на диаграмме, с пошагового инвертированного остаточного блока начинаются только группы 2, 3, 4 и 6. Другими словами, группы 1, 5 и 7 начинаются с бесшагового остаточного блока. Вдобавок каждый бесшаговый блок имеет отождествляющую связь, а пошаговые блоки не имеют отождествляющей связи.



Рис. 8.8 Микроархитектура группы MobileNet v2

Ниже приведен пример имплементации группы модели MobileNet v2. Указанная группа следует традиции, согласно которой первый блок редуцирует размерность, чтобы сократить размер карт признаков. В данном случае первый инвертированный блок выполняется пошагово (сведение признаков), а остальные блоки являются бесшаговыми (сведение признаков отсутствует).

```
def group(x, n_filters, n_blocks, alpha, expansion=6, strides=(2, 2)):
    """ Построить инвертированную остаточную группу
        x : данные на входе в группу
```

```

n_filters : число фильтров
n_blocks : число блоков в группе
alpha : множитель ширины
expansion : множитель для расширения числа фильтров
strides : является ли первый инвертированный остаточный блок пошаговым.
"""
x = inverted_block(x, n_filters, alpha, expansion, strides=strides)
for _ in range(n_blocks - 1):
    x = inverted_block(x, n_filters, alpha, expansion, strides=(1, 1))
return x

```

Строит остаточные блоки →

Первый инвертированный остаточный блок в группе может быть шаговым.

Блок называется *инвертированным остаточным блоком*, потому что он переворачивает (инвертирует) взаимосвязь редукции размерности и расширения размерности, окружающую средний сверточный слой, по сравнению с традиционным остаточным блоком, например, в ResNet50. Вместо того чтобы начинать с бутылочной свертки 1×1 для редукции размерности и заканчивать линейно-проекционной сверткой 1×1 для восстановления размерности, порядок меняется на противоположный. Инвертированный блок начинается с проекционной свертки 1×1 для расширения размерности и заканчивается бутылочной сверткой 1×1 для восстановления размерности (рис. 8.9).

В своем абляционном исследовании, сравнивающем конструкцию остаточного бутылочного блока в MobileNet v1 с конструкцией инвертированного остаточного блока в v2, авторы добились улучшения точности на 1.4 % в топ-1 на ImageNet. Конструкция инвертированного остаточного блока также является эффективнее, сокращая суммарное число параметров с 4.2 млн до 3.4 млн, а число операций `matmul` с 575 млн до 300 млн.

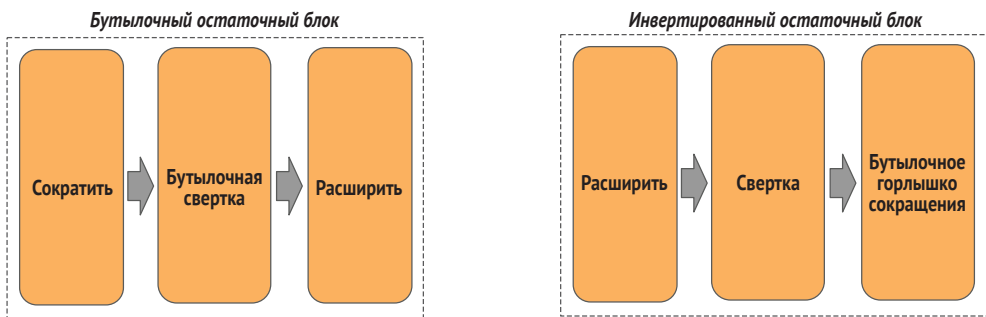


Рис. 8.9 Концептуальное различие между остаточным бутылочным блоком и инвертированным остаточным блоком

Далее мы углубимся в механику, лежащую в основе инверсии. В MobileNet v2 было введено новое метопараметрическое расширение для начальной проекционной свертки 1×1 . Проекционная свертка 1×1 выполняет расширение размерности, а метопараметр определяет величину расширения числа фильтров. Другими слова-

ми, проекционная свертка 1×1 расширяет число карт признаков на высокоразмерное пространство.

Средняя свертка представляет собой свертку вглубь размером 3×3 . За ней следует линейная точечная свертка, которая сокращает карты признаков (также именуемых *каналами*), восстанавливая их до изначального числа. Обратите внимание, что восстановительные свертки используют линейную активацию вместо нелинейной (ReLU). Авторы сочли важным устранить нелинейности в узких слоях, чтобы поддерживать представительную мощность.

Авторы также обнаружили, что активация ReLU теряет информацию в низкоразмерном пространстве, но компенсирует ее при наличии большого числа фильтров. Здесь принято допущение о том, что вход в блок находится в более низкоразмерном пространстве, но увеличивает число фильтров, что является причиной для поддержания использования активации ReLU в первой свертке 1×1 .

Исследователи модели MobileNet v2 называли объем расширения *выразительностью* блока. В своих главных экспериментах они пробова­ли коэффициенты расширения от 5 до 10 и обнаружили малую разницу в точности. Поскольку увеличение расширения приводит к увеличению числа параметров, наблюдая при этом незначительный прирост точности, в своем абляционном исследовании авторы использовали для расширения соотношение 6.

На рис. 8.10 показан инвертированный остаточный блок. Хорошо видно, как изменения в его конструкции сделали еще один шаг вперед в сокращении объема памяти при поддержании точности.

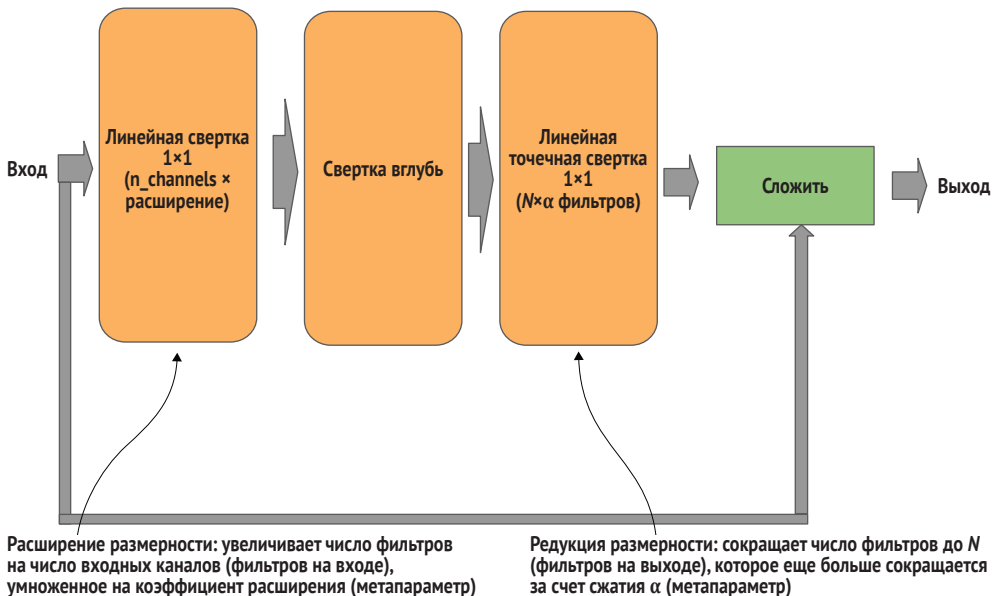


Рис. 8.10 Инвертированный остаточный блок с отождествляющей аббревиатурой инвертирует взаимосвязи сверток 1×1 из v1

Ниже приведен пример имплементации инвертированного остаточного блока. Для контекста вспомните, что вход в инвертированный остаточный блок – это выход из предыдущего блока или стержневой группы в низкоразмерном пространстве. Затем вход проецируется в более высокоразмерное пространство с помощью проекционной свертки 1×1 , где выполняется свертка вглубь 3×3 . Потом точечная линейная свертка 1×1 восстанавливает выход до более низкой размерности данных на входе.

Вот несколько заметных шагов:

- коэффициент ширины применяется к числу выходных фильтров блока: `filters = int(n_filters * alpha)`;
- число входных каналов (карт признаков) определяется по `n_channels = int(x.shape[-1])`;
- линейная проекция 1×1 применяется, когда коэффициент расширения больше 1;
- операция сложения `Add()` выполняется для каждого блока, кроме первого блока в первой группе: если `n_channels == filters and strides == (1, 1)`.

```
def inverted_block(x, n_filters, alpha, expansion=6, strides=(1, 1)):
    """ Построить инвертированный остаточный блок
        x : данные на входе в блок
        n_filters : число фильтров
        alpha : множитель ширины
        expansion : множитель для расширения числа фильтров
        strides : сдвиговые шаги
    """
    shortcut = x # Запомнить входные данные
    filters = int(n_filters * alpha)
    n_channels = int(x.shape[-1])
    if expansion > 1:
        # Линейная свертка 1x1
        x = Conv2D(expansion * n_channels, (1, 1), padding='same')(x)
        x = BatchNormalization()(x)
        x = ReLU(6.)(x)
    if strides == (2, 2):
        x = ZeroPadding2D(padding=((0, 1), (0, 1)))(x)
        padding = 'valid'
    else:
        padding = 'same'
    x = DepthwiseConv2D((3, 3), strides, padding=padding)(x)
    x = BatchNormalization()(x)
    x = ReLU(6.)(x)
    x = Conv2D(filters, (1, 1), strides=(1, 1), padding='same')(x)
    x = BatchNormalization()(x)
```

Применяет множитель ширины к числу карт признаков для точечной свертки

Выполняет расширение размерности, если не первый блок в группе

Добавляет дополнение нулями в карту признаков при наличии пошаговой свертки (сведение признаков)

Свертка вглубь 3×3

Линейная точечная свертка 1×1

```
if n_channels == filters and strides == (1, 1):
    x = Add()(shortcut, x)
return x
```

Складывает отождествляющую связь
с выходом, когда число входных фильтров
совпадает с числом выходных фильтров

8.2.4 Классификатор

В версии v2 исследователи использовали традиционный подход с применением слоя GlobalAveragePooling2D, за которым следует плотный слой, рассмотренный нами в разделе 5.4 главы 5 о крупных передовых моделях. Ранние сети, такие как AlexNet, ZFNet и VGG, разглаживают бутылочный слой (окончательные карты признаков), за которым затем следует один или несколько скрытых плотных слоев, перед последним плотным слоем для классифицирования. Например, в VGG использовалось два слоя из 4096 узлов перед последним плотным слоем для классифицирования.

По мере совершенствования усвоения представлений, начиная с ResNet и Inception, необходимость в скрытых слоях в классификаторе отпала, как и необходимость в разглаживающем слое без сведения к бутылочному более низкоразмерному слою. Архитектура MobileNet v2 следовала практике, согласно которой, когда скрытое пространство содержало достаточно прочную предствительную информацию, ее можно еще больше сократить до более низкоразмерного пространства – бутылочный слой. Обладая высокой представительной информацией, модель может затем передавать более низкую размерность, т. н. *вложение*, или *признаковый вектор*, прямо в плотный слой классификатора без необходимости в промежуточных скрытых плотных слоях. На рис. 8.11 показан классификаторный компонент.




Рис. 8.11 Классификаторная группа модели MobileNet v2

В абляционном исследовании авторы сравнивают MobileNet v1 с v2 с задачей классифицирования ImageNet. Архитектура MobileNet v2 достигла 72%-ной точности в топ-1 по сравнению с v1, которая достигла 70.6 %. Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурно-

го реиспользования для MobileNet v2 находится в репозитории на GitHub (<http://mng.bz/Q2rG>).

Далее мы рассмотрим архитектуру SqueezeNet, авторы которой ввели огневой модуль и терминологию макро- и микроархитектур, а также метапараметры для конфигурирования атрибутов микроархитектуры. В то время как другие исследователи того времени проводили разведывательный анализ этой концепции, авторы SqueezeNet придумывали термины для этой инновационной ступени к более поздним достижениям в области поиска макроархитектур, машинного конструирования и консолидации моделей. Когда я впервые прочитал их статью и познакомился со всеми этими концепциями, то для меня результат был ошеломительный, как внезапно погасшая лампочка.

8.3 SqueezeNet

SqueezeNet – это архитектура, представленная совместным исследованием группы DeepScale, Калифорнийского университета в Беркли и Стэнфордского университета в 2016 году. В соответствующей статье «SqueezeNet» (Forrest N. Iandola et al., SqueezeNet: точность на уровне AlexNet с 50-кратным сокращением числа параметров и размером модели < 0.5 Мб, <https://arxiv.org/abs/1602.07360>) Форрест Н. Иандола и соавт. ввели новый тип модуля, *огневой модуль* (fire module), а также терминологию для микроархитектуры, макроархитектуры и метапараметров. Цель авторов состояла в том, чтобы найти архитектуру сверточной нейросети с меньшим числом параметров, но эквивалентной точностью по сравнению с известной моделью AlexNet.

Конструкция огневого модуля была основана на их исследованиях микроархитектуры для достижения этой цели. *Микроархитектура* – это конструкция модулей или групп, а *макроархитектура* – это то, как модули или группы соединены между собой. Введение термина «метапараметры» помогло лучше различать, что такое гиперпараметр (подробно обсуждается в главе 10).

Как правило, веса и смещения, которые усваиваются во время тренировки, являются модельными параметрами. Термин «*гиперпараметры*» может дезориентировать. Некоторые исследователи/практики использовали этот термин для обозначения параметров, конфигурируемых для проведения тренировки модели, тогда как другие использовали этот термин также для описания модельной архитектуры (например, слоев и ширины). В статье SqueezeNet авторы применили термин *метапараметры* для обозначения структуры модельной архитектуры, которую можно конфигурировать, например число блоков в группе и число фильтров в расчете на сверточный слой в блоке, а также степень редукции размерности в конце группы.

Авторы рассмотрели в своей статье несколько вопросов. Во-первых, они хотели продемонстрировать конструкцию архитектуры свер-

точной нейросети, которая помещалась бы на мобильном устройстве и при этом удерживала точность, сопоставимую с AlexNet на наборе данных ImageNet 2012. В этом отношении авторы эмпирически достигли тех же результатов, что и AlexNet, с сокращением параметров в 50 раз.

Во-вторых, они хотели продемонстрировать архитектуру малой сверточной нейросети, которая сохраняла бы точность при сжатии. Здесь авторы достигли тех же результатов без сжатия после выполнения сжатия с помощью алгоритма глубокого сжатия (Deep Compression), который сократил размер модели с 4.8 Мб до 0.47 Мб. Сокращение размера модели до менее 0.5 Мб при сохранении точности AlexNet продемонстрировало практичность размещения моделей на устройствах интернета вещей с крайне ограниченным объемом памяти, таких как микроконтроллеры.

В статье SqueezeNet авторы ссылаются на свои принципы конструирования, позволяющие достигать своих целей, как на стратегии 1, 2 и 3:

- *стратегия 1* – использовать в основном фильтры 1×1 , которые позволяют сокращать число параметров в 9 раз, вместо более распространенной традиции использовать фильтры 3×3 . В архитектуре SqueezeNet версии v1.0 использовались фильтры в соотношении 2:1 от 1×1 до 3×3 ;
- *стратегия 2* – сокращать число входных фильтров до слоев 3×3 , чтобы еще больше сокращать число параметров. Они называют этот компонент огневого модуля *слоем сдавливания*;
- *стратегия 3* – откладывать отбор с пониженной частотой из карт признаков до как можно более позднего времени в сети. Это контрастирует с традицией использовать ранний отбор с пониженной частотой для сбережения точности. Авторы использовали сдвиговой шаг 1 на ранних сверточных слоях и задерживали, используя шаг 2.

Авторы обосновали свои стратегии следующим образом:

стратегии 1 и 2 направлены на разумное сокращение числа параметров в сверточной нейросети при попытке сохранить точность. Стратегия 3 заключается в максимизации точности при ограниченном бюджете параметров.

Авторы назвали свою архитектуру в честь своей конструкции огневого блока, в котором используется операция сдавливания, за которой следует операция расширения.

8.3.1 Архитектура

Архитектура SqueezeNet состоит из стержневой группы, трех огневых групп, включающих в общей сложности восемь огневых блоков (в статье именуемых *модулями*), и классификаторной группы. Авторы прямо не указали причину, почему они выбрали три огневые груп-

пы и восемь огневых блоков, но описали разведывательный анализ макроархитектуры, который продемонстрировал экономически эффективный метод конструирования модели для определенного отпечатка памяти и диапазона точности, просто тренируя разные комбинации чисел блоков в расчете на группу и размеры входных-выходных фильтров.

На рис. 8.12 показана архитектура. В макроархитектурной проекции вы видите три огневые группы. Усвоение признаков проводится в стержневой группе и первых двух огневых группах. Последняя огневая группа взаимно накладывается на усвоение признаков и классифицирование с классификационной группой.

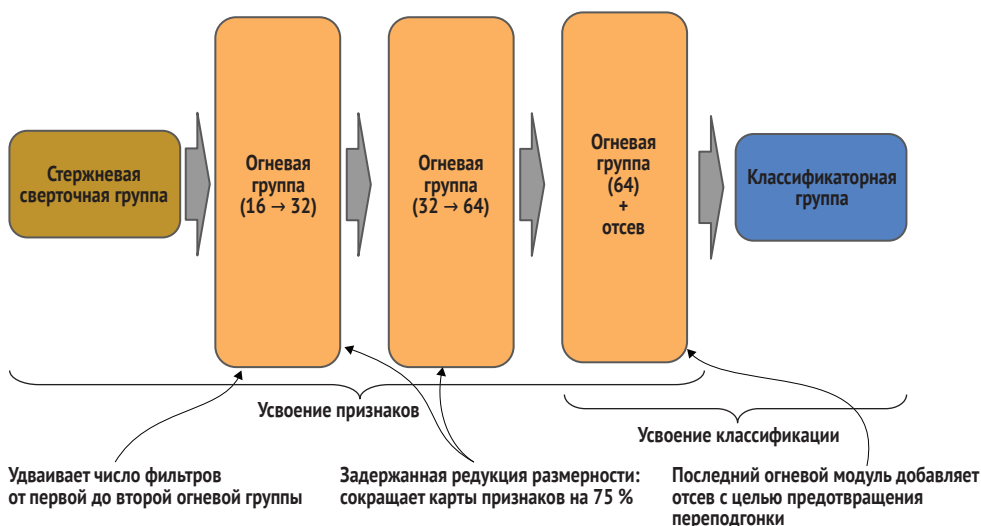


Рис. 8.12 Макроархитектура SqueezeNet

Первые две огневые группы удваивают число карт признаков от входа до выхода, начиная с 16, удваивая до 32, а затем снова удваивая до 64. Как первая, так и вторая огневые группы задерживают редукцию размерности до конца группы. Последняя огневая группа не выполняет ни удвоения карт признаков, ни редукции размерности, но добавляет отсев с целью выполнения регуляризации в конце группы. Этот последний шаг отличался от традиционной в то время практики, согласно которой слой отсева в противном случае помещался бы в классификационную группу после бутылочного слоя (после сокращения и разглаживания карт признаков в 1-мерный вектор).

8.3.2 Стержень

В стержневом компоненте используется сверточный слой грубого уровня 7×7 , который был традицией того времени, в отличие от нынешней традиции использовать стопку сверток 5×5 или разложен-

ную стопку из двух сверточных слоев 3×3 . Стержень выполняет агрессивное сокращение карт признаков, которое продолжает оставаться нынешней традицией.

Грубая свертка 7×7 является шаговой (сведение признаков) для сокращения на 75 %, а за ней следует слой максимального сведения для дальнейшего сокращения на 75 %, в результате чего карты признаков составляют 6 % от размера входных каналов. На рис. 8.13 изображен стержневой компонент.

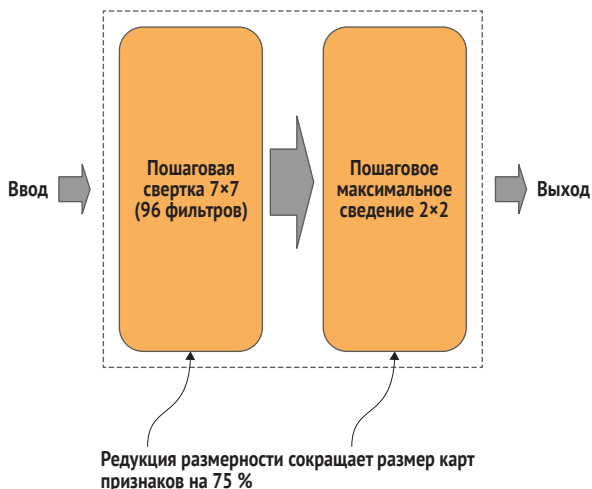


Рис. 8.13 Стержневая группа модели SqueezeNet

8.3.3 Ученик

Ученик состоит из трех огневых групп. Первая огневая группа имеет вход из 16 фильтров (каналов) и выход из 32 фильтров (каналов). Напомним, что стержень выдает 96 каналов, поэтому первая огневая группа сокращает размерность на входе, сокращая число фильтров до 16. Вторая огневая группа удваивает это число, имея на входе 32 фильтра (канала) и на выходе 64 фильтра (канала).

Как первая, так и вторая огневые группы состоят из нескольких огневых блоков. Во всех, кроме последнего огневого блока, используется одинаковое число входных фильтров. Последний огневой блок удваивает число фильтров для выхода. Обе огневые группы задерживают отбор с пониженной частотой из карт признаков до конца группы со слоем MaxPooling2D.

Третья огневая группа состоит из одного огневого блока численностью 64 фильтра, за которым следует слой отсева для регуляризации, перед классификаторной группой. Это слегка отличается от традиции того времени, поскольку отсеивающий слой модели SqueezeNet появляется в классификаторе перед бутылочным слоем, а не после бутылочного слоя. На рис. 8.14 изображена огневая группа.

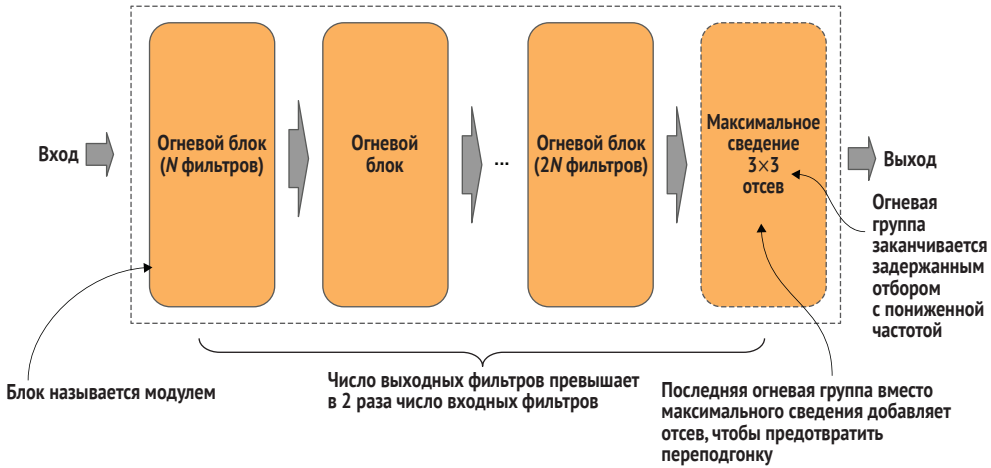


Рис. 8.14 В последней огневой группе групповой микроархитектуры SqueezeNet вместо максимального сведения используется отсев

Ниже приведен пример имплементации первой и второй огневых групп. Обратите внимание, что параметр `filters` является списком, в котором каждый элемент соответствует огневому блоку, а значение – числу фильтров для этого блока. Например, рассмотрим первую огневую группу, которая состоит из трех огневых блоков; на входе имеется 16 фильтров, а на выходе – 32 фильтра. Параметром `filters` будет список `[16, 16, 32]`.

После добавления в группу всех огневых блоков добавляется слой `MaxPooling2D` для задержанного отбора с пониженной частотой:

```
def group(x, filters):
    ''' Построить огневую группу
    Добавляет огневые блоки (модули) в группу
    x : данные на входе в группу
    filters: список числа фильтров в расчете на огневой блок (модуль)
    '''
    for n_filters in filters:
        x = fire_block(x, n_filters)
        Добавляет задержанный отбор с пониженной частотой в конец группы
    x = MaxPooling2D((3, 3), strides=(2, 2))(x)
    return x
```

Рисунок 8.15 иллюстрирует огневой блок, который состоит из двух сверточных слоев. Первый слой – это слой сдавливания, а второй слой – слой расширения. Слой *сдавливания* сокращает или сжимает число входных каналов до более низкой размерности за счет использования бутылочной свертки 1×1 , поддерживая при этом информацию, достаточную для последующей свертки в слое расширения. Операция сдавливания существенно понижает число параметров и соответствующих операций `matmul`. Другими словами, бутылочная свертка 1×1 усваивает наилучший способ максимизировать сдавливание числа карт признаков в меньшее число карт признаков, со-

храня при этом возможность выделения признаков в последующем слое расширения.

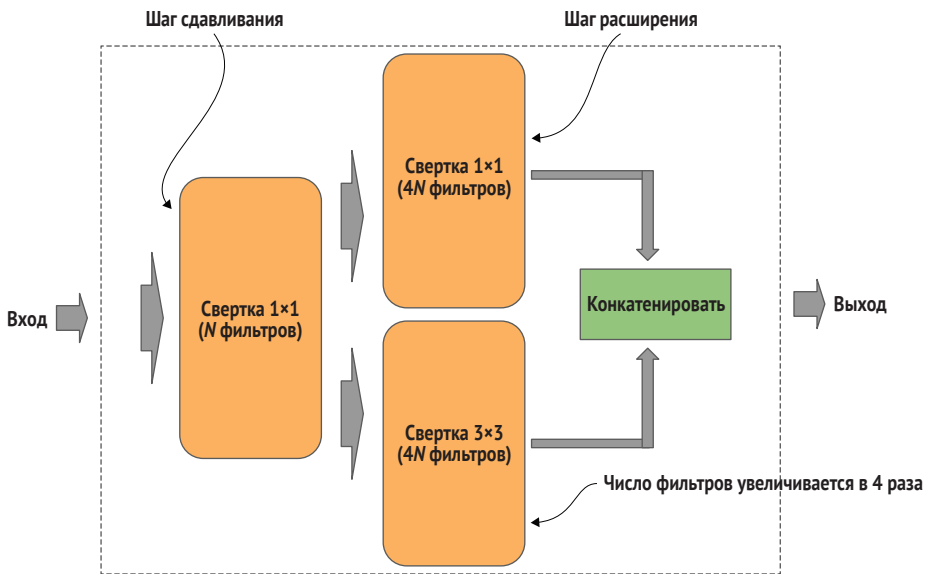


Рис. 8.15 Огневой блок модели SqueezeNet

Слой расширения представляет собой разветвление из двух сверток: линейно-проекционной свертки 1×1 и свертки 3×3 , где происходит выделение признаков. Выходы (карты признаков) из сверток затем конкатенируются. Слой расширения расширяет число карт признаков в 8 раз.

Давайте возьмем пример. Данные на входе в первый огневой блок из стержня составляют 96 карт признаков (каналов), а слой сжатия сокращает их до 16 карт признаков. Затем слой расширения расширяет в 8 раз, в результате чего на выходе снова получается 96 карт признаков. Следующий (второй) огневой блок опять сжимает их до 16 карт признаков и т. д.

Ниже приведен пример имплементации огневого блока. Блок начинается с бутылочной свертки 1×1 для слоя сжатия. Выход squeeze из слоя сжатия разветвляется на две параллельные свертки расширения $\text{expand}1 \times 1$ и $\text{expand}3 \times 3$. Наконец, данные на выходе из двух сверток расширения конкатенируются вместе.

```
def fire_block(x, n_filters):
    ''' Построить огневой блок
        x : данные на входе в блок
        n_filters: число фильтров
    '''
    squeeze = Conv2D(n_filters, (1, 1), strides=1, activation='relu',
                     padding='same')(x)
```

Слой сжатия
с бутылочной сверткой 1×1

```

expand1x1 = Conv2D(n_filters * 4, (1, 1), strides=1, activation='relu',
padding='same')(squeeze)
expand3x3 = Conv2D(n_filters * 4, (3, 3), strides=1, activation='relu',
padding='same')(squeeze)

```

```

x = Concatenate()([expand1x1, expand3x3])
return x

```

Разветвленный выход из слоя возбуждения конкатенируется вместе

Слой расширения разветвляется на свертки 1×1 и 3×3 и удваивает число фильтров

8.3.4 Классификатор

Классификатор не следует традиционной практике, когда за слоем `GlobalAveragingPooling2D` следует плотный (Dense) слой, в котором число выходных узлов равно числу классов. Вместо этого в нем используется сверточный слой, число фильтров равно числу классов, а за сверточным слоем следует слой `GlobalAveragingPooling2D`. Такая компоновка сокращает каждый предыдущий фильтр (класс) до одного значения. Выходы из слоя `GlobalAveragingPooling2D` затем пропускаются через активацию softmax, чтобы получить распределение вероятностей по всем классам.

Давайте вернемся к традиционному классификатору. В традиционном классификаторе окончательные карты признаков сокращаются и разглаживаются до более низкой размерности в бутылочном слое, как правило, с помощью `GlobalAveragingPooling2D`. Теперь у нас будет 1 пиксел в расчете на карту признаков в виде 1-мерного вектора (вложения). Этот 1-мерный вектор затем передается в плотный слой, где число узлов равно числу выходных классов.

На рис. 8.16 показан классификаторный компонент. В модели SqueezeNet окончательные карты признаков пропускаются через линейную проекцию 1×1, которая учится проецировать окончательные

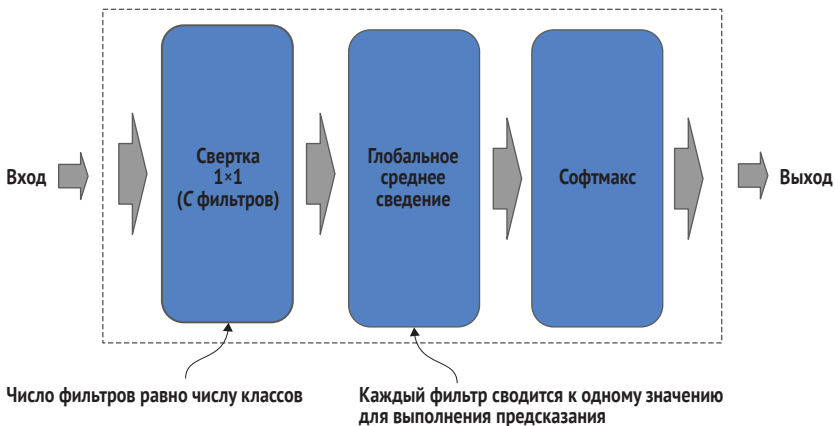


Рис. 8.16 Классификаторная группа модели SqueezeNet, в которой для классифицирования вместо плотного слоя используется свертка

карты признаков в новый набор, который в точности равен числу выходных классов. Теперь эти спроецированные карты признаков, каждая из которых соответствует классу, сокращаются до одного пиксела в расчете на карту признаков и разглаживаются, превращаясь в 1-мерный вектор, длина которого в точности равна числу выдаваемых классов. Затем этот 1-мерный вектор пропускается через softmax для предсказания.

В чем принципиальная разница? В традиционном классификаторе плотный слой усваивает классификацию. В данной мобильной версии классификацию усваивает линейная проекция 1×1 .

Ниже приведен пример имплементации классификатора. В данном примере входные данные, которые являются окончательными картами признаков, пропускаются через слой Conv2D, который выполняет линейную проекцию 1×1 на число выходных классов. Последующие карты признаков затем сводятся к однопиксельному 1-мерному вектору с помощью слоя GlobalAveragePooling2D:

```
def classifier(x, n_classes):
    ''' Построить классификатор
        x : данные на входе в классификатор
        n_classes: число выходных классов
    '''
    x = Conv2D(n_classes, (1, 1), strides=1, activation='relu',
               padding='same')(x)
    x = GlobalAveragePooling2D()(x)
    x = Activation('softmax')(x)
    return x
```

Задает число фильтров
равным числу классов

Сокращает каждый фильтр (класс)
до одного-единственного значения
для классифицирования

Далее давайте углубимся в конструкцию классификатора, построив его с использованием традиционного подхода крупных передовых моделей. На рис. 8.17 показан традиционный подход. Окончательные карты признаков глобально сводятся в матрицу 1×1 (одно значение) каждая. Затем указанные матрицы разглаживаются в 1-мерный

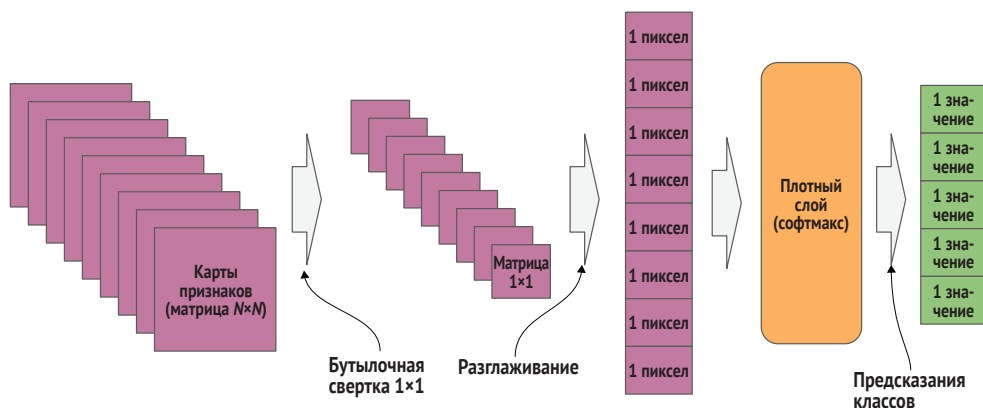


Рис. 8.17 Обработка карт признаков в традиционном крупном передовом классификаторе

вектор, длина которого равна числу карт признаков (например, 2048 в ResNet). Потом 1-мерный вектор пропускается через плотный слой с активацией softmax, которая выдает вероятность каждого класса.

На рис. 8.18 показан подход, принятый в SqueezeNet. Карты признаков обрабатываются бутылочной сверткой 1×1 , которая сокращает число карт признаков до числа классов. По сути, это шаг предсказания класса – за исключением того, что у нас не одно значение, а матрица $N \times N$. Эти $N \times N$ -матричные предсказания затем глобально сводятся в матрицы 1×1 , которые потом разглаживаются в 1-мерный вектор, в котором каждый элемент является вероятностью соответствующего класса.

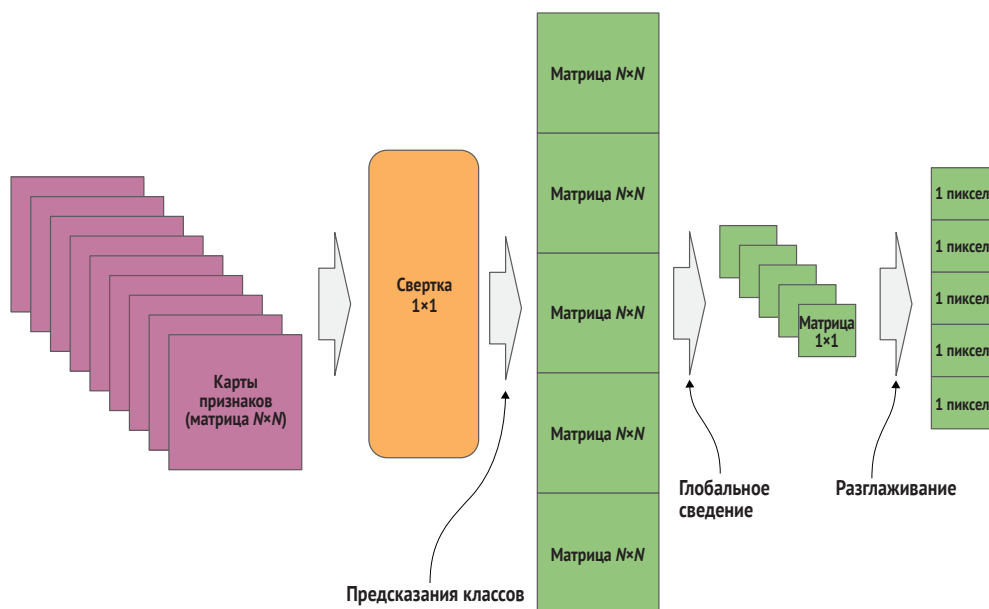


Рис. 8.18 Использование свертки вместо плотного слоя для классифицирования

8.3.5 Обходные соединения

В своем абляционном исследовании авторы экспериментировали с микроархитектурным поиском блока с использованием отождествляющей связи, введенной в архитектуре ResNet, которую они назвали *обходными соединениями*. Архитектура SqueezeNet, как они заявили в своей статье, базируется на «широком и в значительной степени неразведанном конструктивном пространстве архитектур сверточных нейросетей». Часть их исследований включала то, что они называли *конструктивным пространством микроархитектур*. Они указали, что находились под влиянием сравнения A/B авторов архитектуры ResNet на ResNet34 с обходными соединениями и без них и получили повышение производительности на 2 % с обходным соединением.

Авторы экспериментировали с тем, что они называли простым обходным путем и сложным обходным путем. В *простом обходном пути* они получили увеличение точности на ImageNet на 2.9 % в топ-1 и на 2.2 % в топ-5 без увеличения вычислительной сложности. Таким образом, их улучшения были сопоставимы с теми, которые наблюдали авторы архитектуры ResNet.

В *сложном обходном пути* они наблюдали меньшее улучшение с увеличением точности всего на 1.3 % при увеличении размера модели с 4.8 Мб до 7.7 Мб. При простом обходном пути размер модели не увеличивался. Авторы пришли к выводу, что простого обходного пути было достаточно.

Простой обходной путь

При простом обходном пути отождествляющая связь возникает только в первом огневом блоке (входе в группу) и огневом блоке до удвоения фильтров. На рис. 8.19 показана огневая группа с простым обходным соединением. Первый огневой блок в группе имеет обходное соединение (отождествляющую связь), а затем огневой блок, предшествующий огневому блоку, удваивает число выходных каналов (карт признаков).

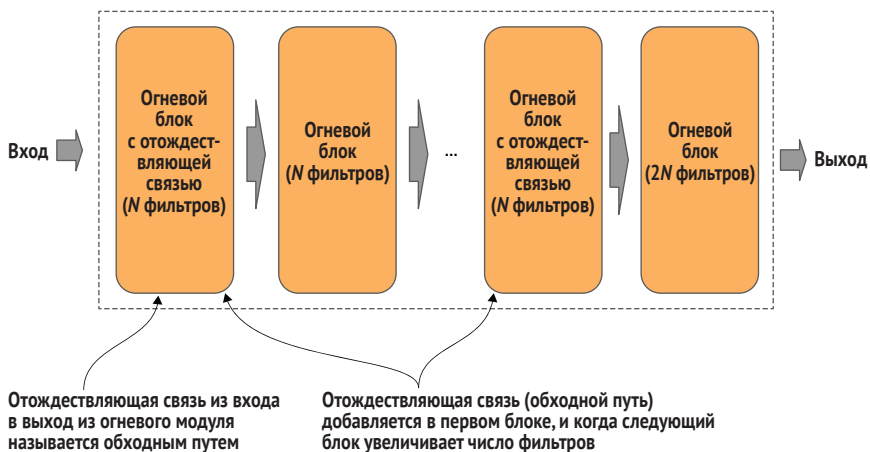


Рис. 8.19 Группа модели SqueezeNet с простыми обходными блоками

Теперь давайте приглядимся поближе к огневому блоку с простым обходным соединением (отождествляющей связью). Он показан на рис. 8.20. Обратите внимание, что данные на входе в блок складываются с выходом из операции конкатенации.

Давайте пройдемся по нему в пошаговом режиме. Во-первых, мы знаем, что при операции матричного сложения число карт признаков на входе должно соответствовать числу выходов из операции конкатенации. Для большого числа огневых блоков это верно. Например, из стержневой группы у нас поступают на вход 96 карт признаков,

которые сокращаются до 16 в слое сдвливания, а затем расширяются в 8 раз (обратно до 96), пройдя через слой расширения. Поскольку число карт признаков на входе равно их числу на выходе, мы можем добавить отождествляющую связь. Но это не относится ко всем огненным блокам, и поэтому только у их подмножества есть обходное соединение.

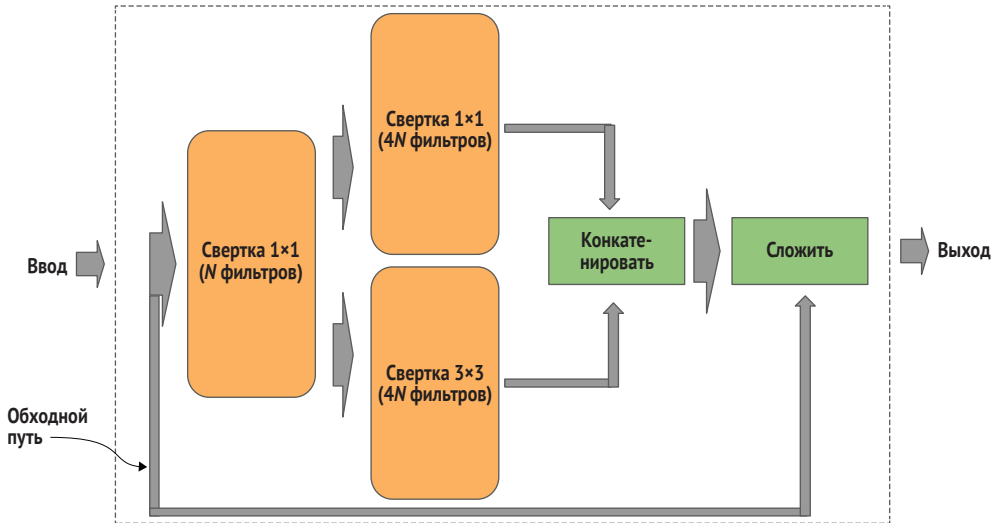


Рис. 8.20 Огневой блок модели SqueezeNet с отождествляющей связью

Ниже приведен пример имплементации огневого блока с простым обходным соединением (отождествляющей связью). В данной имплементации мы передаем дополнительный параметр `bypass`. Если он истинен, то мы добавляем окончательный слой в конце блока, который выполняет матричное сложение (`Add()`) с выходом из конкатенации:

```
def fire_block(x, n_filters, bypass=False):
    ''' Построить огневой блок
        x : данные на входе в блок
        n_filters: число фильтров в блоке
        bypass : имеет ли блок отождествляющую аббревиатуру
    '''
    shortcut = x

    squeeze = Conv2D(n_filters, (1, 1), strides=1, activation='relu',
                     padding='same')(x)
    expand1x1 = Conv2D(n_filters * 4, (1, 1), strides=1, activation='relu',
                     padding='same')(squeeze)
    expand3x3 = Conv2D(n_filters * 4, (3, 3), strides=1, activation='relu',
                     padding='same')(squeeze)

    x = Concatenate()([expand1x1, expand3x3])
```



```

if bypass:
    x = Add()([x, shortcut])
return x
"""

```

Когда параметр `bypass` истинен, вход (`shortcut`) складывается путем матричного сложения с выходом из огневого блока

Сложный обходной путь

В следующем микроархитектурном поиске авторы развели сложение линейной проекции с оставшимися огневыми блоками без отождествляющей связи (простого обходного пути). Линейная проекция будет проецировать число входных признаков, равное числу выходных карт признаков после операции конкатенации. Они называли это соединение *сложным обходным путем*.

Цель состояла в том, чтобы посмотреть, приведет ли это к дальнейшему повышению точности топ-1/топ-5, хотя и за счет увеличения размера модели. Как я отмечал ранее, их эксперименты показали, что использование сложного обходного пути наносит ущерб цели. На рис. 8.21 изображена огневая группа, в которой остальные огневые блоки без простого обходного пути (отождествляющей связи) имеют сложный обходной путь (линейно-проекционную связь).

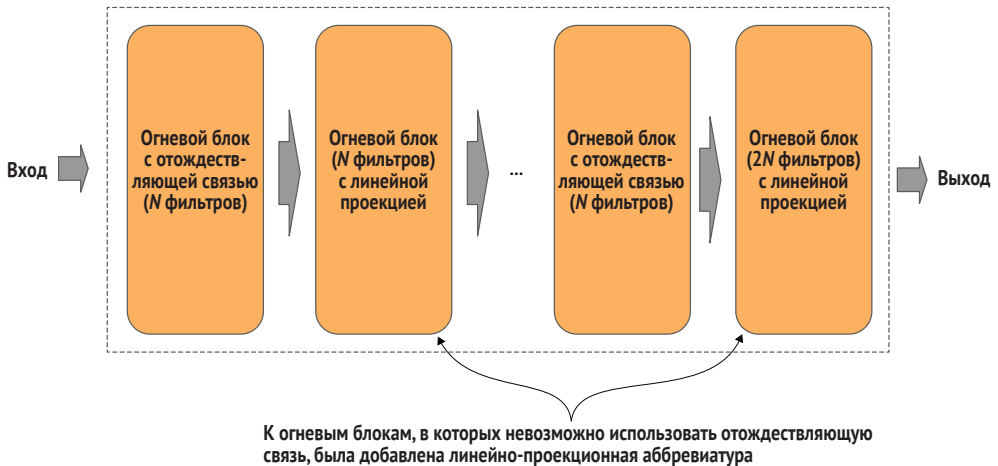


Рис. 8.21 Группа модели SqueezeNet с огневыми блоками с проекционной аббревиатурой (сложным обходным путем)

Теперь давайте рассмотрим показанный на рис. 8.22 огневой блок со сложным обходным путем подробнее. Обратите внимание, что линейная проекция 1×1 на отождествляющей связи увеличивает число фильтров (каналов) на 8. Это число должно соответствовать размеру выхода из конкатенации выходов из разветвленных 1×1 и 3×3 , оба из которых увеличили размер выхода на 4 ($4 + 4 = 8$). Использование линейной проекции 1×1 на отождествляющей связи как раз и отличает сложный обходной путь от простого.

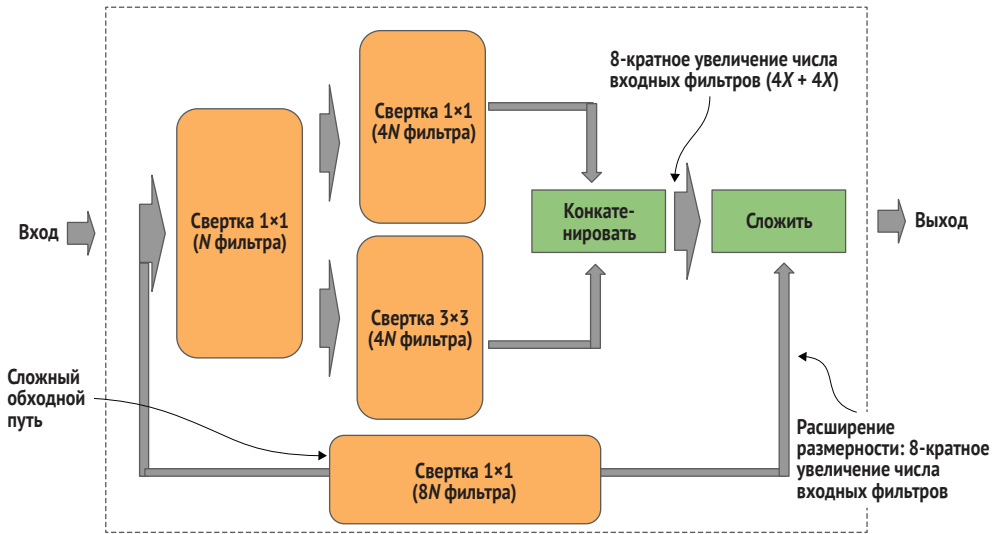


Рис. 8.22 Огневой блок модели SqueezeNet с проекционной аббревиатурой (сложным обходным путем)

В абляционном исследовании использование простого обходного пути повысило точность по сравнению с классической/ванильной моделью SqueezeNet на ImageNet с 57.5 % до 60.4 %. Для сложного обходного пути точность увеличилась всего до 58.8 %. Авторы не сделали никакого вывода о причинах, кроме как сказали, что это было интересно. Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для SqueezeNet находится в репозитории на GitHub (<http://mng.bz/XYmv>).

Далее мы рассмотрим модель ShuffleNet, авторы которой ввели точечные групповые свертки и операции перетасовки (транспонирования) каналов с целью увеличения числа карт признаков без увеличения вычислительной сложности и размера.

8.4 ShuffleNet v1

Одна из проблем крупных сетей заключается в том, что им требуется много карт признаков, обычно тысячи, что означает высокую вычислительную стоимость. Так, в 2017 году Сянью Чжан и соавт. в Face++ представили способ создания большого числа карт признаков при существенном снижении вычислительной стоимости. Эта новая архитектура, получившая название ShuffleNet v1 (Xiangyu Zhang et al., <https://arxiv.org/abs/1707.01083>), была разработана специально для устройств с низкой вычислительной мощностью, обычно используемых в мобильных телефонах, беспилотных летательных аппаратах и роботах.

В указанной архитектуре были введены новые слоевые операции: групповые точечные свертки и перетасовка каналов. По сравнению с архитектурой MobileNet авторы обнаружили, что ShuffleNet обеспечивает превосходную производительность со значительным отрывом: абсолютная ошибка на ImageNet топ-1 на 7.8 % ниже на уровне 40 Мфлоп. В то время как авторы сообщили о повышении точности по сравнению с аналогами MobileNet, модели MobileNet по-прежнему предпочитались для производства, хотя в настоящее время их заменяют модели EfficientNet.

8.4.1 Архитектура

Архитектура ShuffleNet состоит из трех групп перетасовки, которые в статье авторов называются *стадиями*. Архитектура соответствовала традиционной практике, когда каждая группа удваивала число выходных каналов или карт признаков по сравнению с предыдущей группой. На рис. 8.23 показана архитектура ShuffleNet.

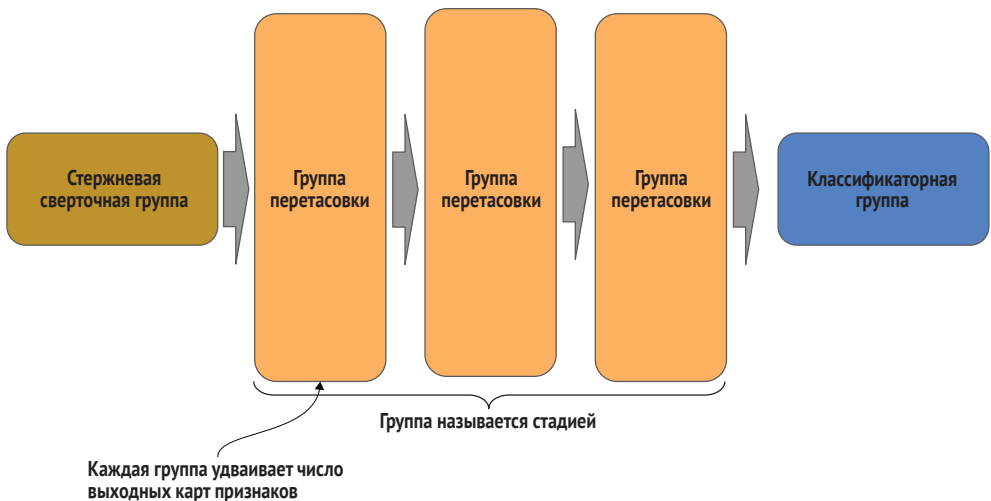


Рис. 8.23 В макроархитектуре ShuffleNet v1 каждая группа удваивает число выходных карт признаков

8.4.2 Стержень

В стержневом компоненте используется менее грубый сверточный слой 3×3 по сравнению с другими мобильными передовыми моделями того времени, в которых обычно использовались 7×7 либо стопка из двух сверточных слоев 3×3 . Стержень, изображенный на рис. 8.24, выполняет агрессивное сокращение карт признаков, которое по-прежнему является действующей традицией. Свертка 3×3 выполняется пошагово (сведение признаков) для сокращения на 75 %, за которой следует слой максимального сведения для дальнейшего

сокращения на 75 %, в результате чего размер карт признаков составляет 6 % от размера входных каналов. Практика сокращения размера канала с входного до 6 % по-прежнему остается традиционной.



Рис. 8.24 Стержневая группа модели ShuffleNet комбинирует сведение признаков и максимальное сведение для сокращения выходных карт признаков до 6 % от размера входных данных

8.4.3 Ученик

Каждая группа в ученическом компоненте состоит из блока пошаговой перетасовки (в статье именуемого *единицей*, или юнитом), за которым следует один или несколько блоков перетасовки. Блок пошаговой перетасовки удваивает число выходных каналов при одновременном сокращении размера каждого канала на 75 %. Поступательное удвоение числа фильтров и, следовательно, выходных карт признаков в расчете на признак было традицией того времени и продолжается по сей день. Также по традиции, когда группа удваивает число выходных карт признаков, их размеры сокращаются, чтобы предотвратить резкий рост параметров по мере углубления в слой.

Группа

Как и в моделях MobileNet v1 /v2, группа модели ShuffleNet выполняет сокращение карт признаков в начале группы с помощью блока пошаговой перетасовки. Это отличается от SqueezeNet и крупных передовых моделей, которые откладывают сокращение карт признаков до конца группы. За счет сокращения размера в начале группы число параметров и операций *matmul* существенно сокращается, но за счет меньшей представительной мощности.

На рис. 8.25 показана группа перетасовки. Указанная группа начинается с блока пошаговой перетасовки, который сокращает размер

карт признаков в начале группы, и затем следует один или несколько блоков перетасовки. Блок пошаговой перетасовки и последующие блоки перетасовки удваивают число фильтров из предыдущей группы. Например, если в предыдущей группе было 144 фильтра, то текущая группа удвоится до 288.

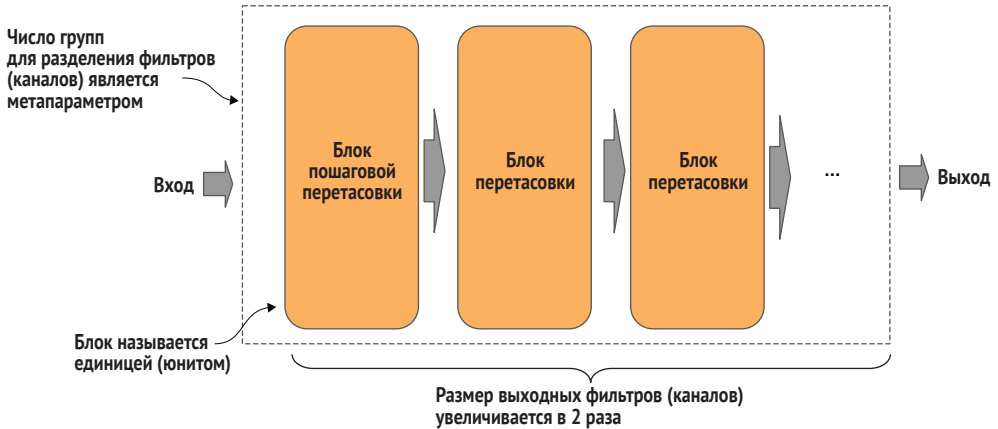


Рис. 8.25 Групповая микроархитектура модели ShuffleNet

Ниже приведен пример имплементации группы перетасовки. Параметр `n_blocks` – это число блоков в группе, а `n_filters` – число фильтров для каждого блока. Параметр `reduction` является метапараметром для редукции размерности в блоке перетасовки (обсуждается далее), а параметр `n_partitions` – метапараметром, используемым для разделения карт признаков с целью перетасовки каналов (обсуждается впоследствии). Первый блок представляет собой блок пошаговой перетасовки, а остальные блоки являются бесшаговыми: `for _ in range(n_blocks-1)`.

```
def group(x, n_partitions, n_blocks, n_filters, reduction):
```

```
    ''' Построить группу перетасовки
```

```
        x : данные на входе в группу
```

```
        n_partitions : число групп, на которые разделять карты признаков (каналы)
```

```
        n_blocks : число блоков перетасовки для этой группы
```

```
        n_filters : число выходных фильтров
```

```
        reduction : редукция размерности
```

Добавляет оставшиеся блоки
бесшаговой перетасовки

```
    ...
```

```
    x = strided_shuffle_block(x, n_partitions, n_filters, reduction)
```

```
    for _ in range(n_blocks-1):
```

```
        x = shuffle_block(x, n_partitions, n_filters, reduction)
```

```
    return x
```

Блок

Блок перетасовки основан на остаточном блоке В (1, 3, 1), где свертка 3×3 представляет собой свертку вглубь (как в MobileNet). Авторы

отметили, что такие архитектуры, как Xception и ResNeXt, становятся менее эффективными в чрезвычайно малых сетях из-за дорогостоящих плотных сверток 1×1 . В целях решения этой проблемы они заменили точечные свертки 1×1 точечными групповыми свертками, чтобы сократить вычислительную сложность. На рис. 8.26 показана разница в конструкции.

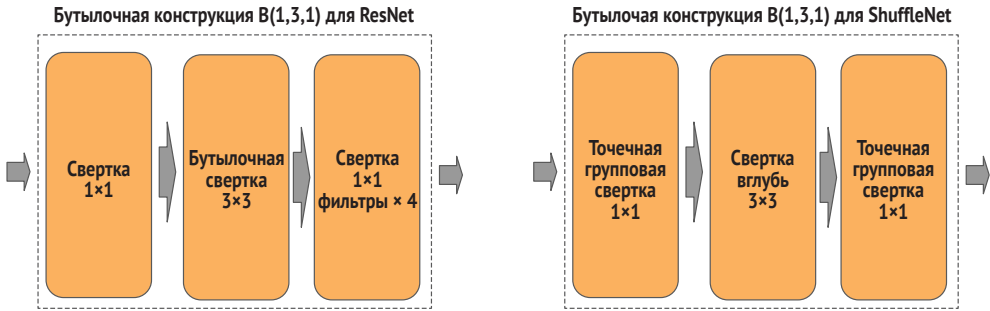


Рис. 8.26 Сравнение конструкций $B(1,3,1)$ в ResNet и ShuffleNet

Первая точечная групповая свертка также выполняет редукцию размерности числа фильтров на входе в блок, когда параметр *reduction* составляет < 1 ($\text{reduction} * \text{n_filters}$), а затем он восстанавливается в выходных каналах с помощью второй точечной групповой свертки, чтобы сочетать вход с остаточным блоком для операции матричного сложения.

Они также отклонились от практики, принятой в Xception, использовать ReLU после свертки вглубь, чтобы применять линейную активацию. Их логика этого изменения неясна, равно как и преимущество использования линейной активации. В документе просто говорится: «Использование пакетной нормализации (BN) и нелинейности является аналогичным [ResNet, ResNeXt], за исключением того, что мы не используем ReLU после свертки вглубь, как предложено [Xception]». Между первой точечной групповой сверткой и сверткой вглубь находится операция перетасовки каналов, обе из которых будут рассмотрены впоследствии.

На рис. 8.27 показан блок перетасовки. Хорошо видно, как перетасовка каналов была вставлена в конструкцию $B(1,3,1)$ остаточного блока перед сверткой вглубь 3×3 , где происходит выделение признаков. Остаточный блок $B(1,3,1)$ представляет собой бутылочную конструкцию, сопоставимую с MobileNet v1, в которой первая свертка 1×1 редуцирует размерность, а вторая свертка 1×1 расширяет размерность. В указанном блоке была продолжена традиция MobileNet сопряжения свертки вглубь 3×3 с точечной групповой сверткой 1×1 для формирования свертки, разделяемой по глубине. Однако он отличается от MobileNet v1 заменой первой бутылочной свертки 1×1 на бутылочную точечную групповую свертку 1×1 .

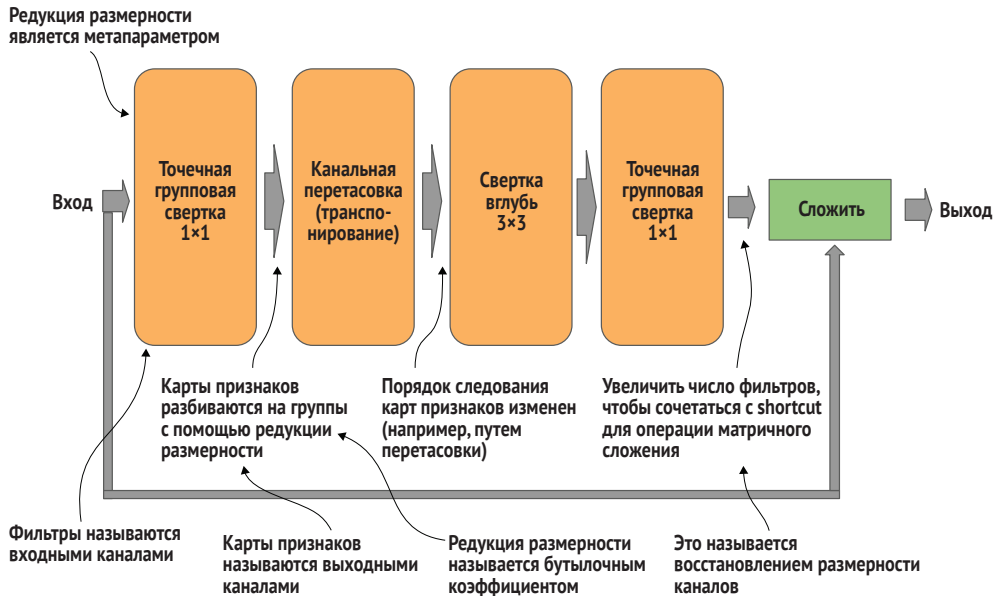


Рис. 8.27 Блок модели ShuffleNet с использованием идиоматической конструкции

Ниже приведен пример имплементации блока перетасовки. Указанный блок начинается с точечной групповой свертки 1×1 , определенной в функции `pw_group_conv()`, где значение параметра `int(reduction * n_filters)` задает редукцию размерности. Далее следует перетасовка каналов, определенная в функции `channel_shuffle()`, за которой следует свертка вглубь (`DepthwiseConv2D`). Потом идет заключительная точечная групповая свертка 1×1 , которая восстанавливает размерность. Наконец, данные на входе в блок подвергаются матричному сложению (`Add()`) с данными на выходе из точечной групповой свертки.

```
def shuffle_block(x, n_partitions, n_filters, reduction):
    ''' Построить блок перетасовки
        x : данные на входе в блок
        n_partitions: число групп, на которые разделять карты признаков (каналы).
        n_filters : число фильтров
        reduction : коэффициент редукции размерности (например, 0.25)
    '''

    shortcut = x  # Первая точечная групповая свертка редуцирует размерность

    x = pw_group_conv(x, n_partitions, int(reduction * n_filters))
    x = ReLU()(x)

    x = channel_shuffle(x, n_partitions)  # Перетасовка каналов

    x = DepthwiseConv2D((3, 3), strides=1, padding='s')
    x = BatchNormalization()(x)  # Свертка вглубь 3x3
```

```

x = pw_group_conv(x, n_partitions, n_filters)
x = Add()(shortcut, x)
x = ReLU()(x)
return x

```

Вторая групповая свертка
восстанавливает
размерность

Складывает вход (shortcut)
с выходом из блока

Точечная групповая свертка

Ниже приведен пример имплементации точечной групповой свертки. Функция начинается с определения числа входных каналов (`in_filters = x.shape[-1]`). Далее число каналов в группе определяется путем деления числа входных каналов на число групп (`n_partitions`). Затем карты признаков пропорционально разбиваются по группам (`lambda`), и каждая группа пропускается через отдельную точечную свертку 1×1 . Наконец, выходы из групповых сверток конкатенируются вместе и пропускаются через слой пакетной нормализации.

```

def pw_group_conv(x, n_partitions, n_filters):
    ''' Точечная групповая свертка
        x : входной тензор
        n_groups : число групп, на которые разделять карты признаков (каналы)
        n_filters : число фильтров
    '''
    in_filters = x.shape[-1]
    grp_in_filters = in_filters // n_partitions
    grp_out_filters = int(n_filters / n_partitions + 0.5)

    groups = []
    for i in range(n_partitions):
        group = Lambda(lambda x: x[:, :, :, grp_in_filters * i:
                                   grp_in_filters * (i + 1)])(x)
        conv = Conv2D(grp_out_filters, (1,1), padding='same',
                      strides=1)(group)
        groups.append(conv)
    x = Concatenate()(groups)
    x = BatchNormalization()(x)
    return x

```

Вычисляет число входных карт признаков (каналов) →

Вычисляет число входных и выходных фильтров (каналов) в расчете на группу. Обратите внимание на округление вверх

Выполняет линейную точечную свертку 1×1 по каждой группе каналов

Поддерживает групповые точечные свертки в списке →

Разрезает карты признаков по канальной группе

Конкатенирует выходы из групповых точечных сверток вместе

Выполняет пакетную нормализацию конкатенированных групповых выходов (карт признаков)

Блок пошаговой перетасовки

Блок пошаговой перетасовки отличается следующим:

- размерность аббревиатурной связи (данные на входе в блок) сокращается операцией среднего сведения 3×3 ;
- остаточные и аббревиатурные карты признаков конкатенируются вместо использования матричного сложения в блоке бесшаговой перетасовки.

Что касается использования конкатенации, то авторы решили «заменить поэлементное сложение канальной конкатенацией, что позво-

ляет легко увеличивать канальную размерность с небольшой избыточной вычислительной стоимостью».

На рис. 8.28 изображен блок пошаговой перетасовки. Вы видите два отличия от блока бесшаговой перетасовки. В аббревиатурную связь было добавлено среднее сведение, которое редуцирует размерность путем сокращения карт признаков до $0.5H \times 0.5W$. Это делается, чтобы ее размер сочетался с размером сведения признаков, которое выполняется пошаговой сверткой вглубь 3×3 , чтобы их можно было конкатенировать – вместо матричного сложения в блоке бесшаговой перетасовки.

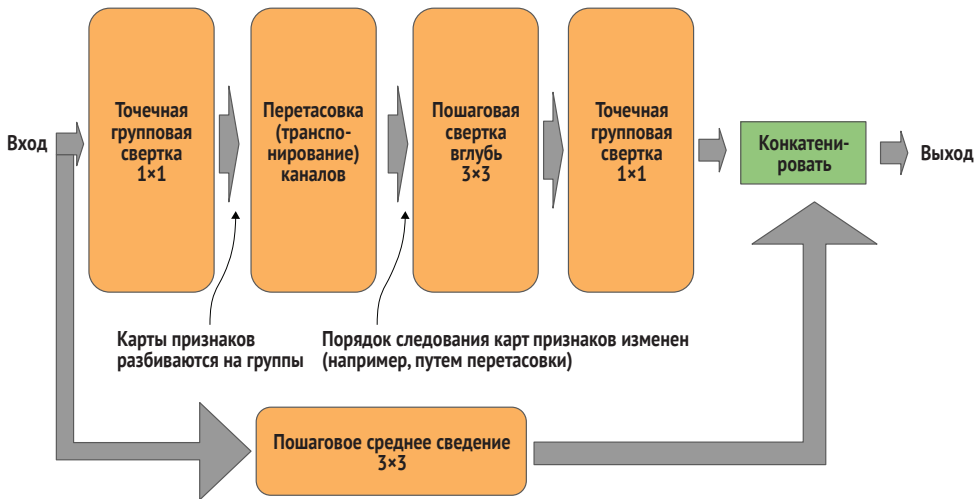


Рис. 8.28 Блок пошаговой перетасовки

Ниже приведен пример имплементации блока пошаговой перетасовки. Параметр `n_filters` – это число фильтров для сверточных слоев в блоке. Параметр `reduction` является метапараметром для дальнейшего утончения сети, а параметр `n_partitions` задает число групп, на которые необходимо разбить карты признаков для точечной групповой свертки.

Функция начинается с создания проекционной аббревиатуры (`shortcut`). Входные данные пропускаются через слой пошагового среднего сведения `AveragePooling2D`, который сокращает размер карт признаков в проекционной аббревиатуре до $0.5H \times 0.5W$.

Затем входные данные пропускаются через точечную групповую свертку 1×1 (`pw_group_conv()`). Обратите внимание, что утончение сети происходит в первой точечной групповой свертке (`int(reduction * n_filters)`). Входные данные подвергаются канальной перетасовке (`channel_shuffle()`), а затем пропускаются через шаговую свертку вглубь 3×3 , которая выполняет выделение и сведение признаков; обратите внимание на отсутствие активации `ReLU`.

Выход из `DepthwiseConv2D()` затем пропускается через вторую точечную групповую свертку 1×1 , выход из которой потом конкатенируется с проекционной аббревиатурой.

```
def strided_shuffle_block(x, n_partitions, n_filters, reduction):
    ''' Построить блок пошаговой перетасовки
        x : данные на входе в блок
        n_partitions : число групп, на которые разделять карты признаков (каналы)
        n_filters : число фильтров
        reduction : коэффициент редукции размерности (например, 0.25)
    '''

    # проекционная аббревиатура
    shortcut = x

    shortcut = AveragePooling2D((3, 3), strides=2, padding='same')(shortcut)
    n_filters -= int(x.shape[-1])

    x = pw_group_conv(x, n_partitions, int(reduction * n_filters))
    x = ReLU()(x)

    x = channel_shuffle(x, n_partitions)

    x = DepthwiseConv2D((3, 3), strides=2, padding='same')(x)
    x = BatchNormalization()(x)

    x = pw_group_conv(x, n_partitions, n_filters)

    x = Concatenate()([shortcut, x])
    x = ReLU()(x)
    return x
```

Использует среднее сведение для бутылочной аббревиатуры

Конкатенирует проекционную аббревиатуру с выходом из блока

На первом блоке число выходных фильтров входной точечной групповой свертки корректируется, чтобы совпадать с выходной точечной групповой сверткой

ПЕРЕТАСОВКА КАНАЛОВ

Перетасовка каналов была разработана для преодоления побочных эффектов, связанных с групповыми свертками, тем самым помогая информации течь по выходным каналам. Групповая свертка значительно снижает вычислительную стоимость, обеспечивая, чтобы каждая свертка работала только с соответствующей входной канальной группой. Как отмечают авторы, если несколько групповых сверток сложены в стопку вместе, то возникает один побочный эффект: выходы из определенного канала выводятся только из малой части входных каналов. Другими словами, каждая групповая свертка лимитирована усвоением следующего уровня выделения признаков для своего фильтра, основываясь только на одной карте признаков (канале), а не на всех или части всех входных карт признаков.

На рис. 8.29 показана разбивка каналов на группы и последующая перетасовка каналов. По сути, перетасовка состоит в строительстве новых каналов, так как каждый перетасованный канал содержит часть каждого другого канала – следовательно, увеличивая поток информации по выходным каналам.




Рис. 8.29 Перетасовка каналов

Давайте рассмотрим этот процесс подробнее. Мы начинаем с группы входных каналов, которые я выделил на диаграмме серым цветом, чтобы обозначить, что они являются разными каналами (не копиями). Затем, в зависимости от настройки разделения, каналы разбиваются на части одинакового размера, которые мы называем *группами*. В нашем изображении каждая группа имеет три отдельных канала. Мы создаем три перетасованные версии трех каналов. Серым оттенком мы обозначаем, что каждый перетасованный канал формируется из части каждого неперетасованного канала, и эта часть отличается для каждого перетасованного канала.

Например, первый перетасованный канал строится из первой трети карт признаков трех неперетасованных каналов. Второй перетасованный канал строится на основе первой трети карт признаков трех неперетасованных каналов и т. д.

Ниже приведен пример имплементации перетасовки каналов. Параметр `n_partitions` задает число групп, на которые следует разделять входные карты признаков, параметр `x`. Мы используем форму входных данных для определения $B \times H \times W \times C$ (где C – это каналы), а затем вычисляем число каналов в группе (`grp_in_channels`).

Следующие три лямбда-операции выполняют вот что:

- 1 реформирует входные данные с $B \times H \times W \times C$ на $B \times W \times W \times G \times C_g$. Добавляется пятая размерность, G (группы), и C реформируется в $G \times C_g$, где C_g – это подмножество каналов в расчете на группу;
- 2 функция `K.permute_dimensions()` выполняет перетасовку каналов, изображенную на рис. 5.27;
- 3 второе реформирование восстанавливает перетасованные каналы обратно в форму $B \times H \times W \times C$.

```
def channel_shuffle(x, n_partitions):
    ''' Имплементирует слой перетасовки каналов
    x : входной тензор
    n_partitions : число групп, на которые следует разделять карты
    признаков (каналы)
    batch, height, width, n_channels = x.shape
    grp_in_channels = n_channels // n_partitions

    x = Lambda(lambda z: K.reshape(z, [-1, height, width, n_partitions,
    grp_in_channels]))(x)

    x = Lambda(lambda z: K.permute_dimensions(z, (0, 1, 2, 4, 3)))(x)
    x = Lambda(lambda z: K.reshape(z, [-1, height, width, n_channels]))(x)
    return x
```

Выводит число входных фильтров (каналов) в расчете на группу →

Получает размерности входного тензора ←

Выделяет каналные группы →

Восстанавливает выходную форму →

Транспонирует порядок следования (перетасовка) каналных групп (т. е. 3, 4 => 4, 3)

В своем абляционном исследовании авторы обнаружили, что наилучший компромисс между сложностью и точностью был при коэффициенте сокращения 1 (без сокращения) и числе групповых разделов, равном 8. Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для ShuffleNet находится в репозитории на GitHub (<http://mng.bz/oGop>).

Далее мы рассмотрим сжатие размера модели для устройства с ограниченным объемом памяти с помощью квантизации и конвертирование/предсказывание с использованием пакета TensorFlow Lite языка Python для развертывания мобильной модели.

8.5 Развертывание

Мы завершим эту главу описанием основ развертывания мобильной сверточной модели. Сначала рассмотрим квантизацию, которая сокращает размер параметров и, следовательно, объем памяти. Квантизация происходит до развертывания модели. Далее мы увидим, как использовать TF Lite для выполнения модели на устройстве с ограниченным объемом памяти. В наших примерах мы применяем среду Python в качестве прокси (посредника). Мы не будем вдаваться в подробности, связанные с Android или iOS.

8.5.1 Квантизация

Квантизация – это процесс сокращения числа битов, представляющих число. В устройствах с ограниченным объемом памяти мы хотим хранить веса в более низком битовом представлении без значительной потери точности.

Поскольку нейронные сети достаточно устойчивы к малым ошибкам в вычислениях, им не требуется столь высокая точность для предсказательного вывода, как для тренировки. Это дает возможность снижать точность весов в мобильной нейронной сети. Традиционное сокращение состоит в замене 32-битовых весовых значений с плавающей точкой дискретной аппроксимацией в виде 8-битовых целых значений. Первостепенное преимущество заключается в том, что для сокращения с 32 бит до 8 требуется всего четверть объема памяти модели.

Во время предсказательного вывода (предсказывания) веса сокращаются до их приближенных 32-битовых значений с плавающей точкой для матричных операций, которые затем пропускаются через активационную функцию. Современные аппаратные ускорители были разработаны для оптимизации этой перешкалирующей операции таким образом, чтобы снижать номинальные вычислительные издержки.

При традиционном сокращении 32-битовые веса с плавающей точкой делятся на корзины (интервалы) в диапазоне целых чисел. Для 8-битового значения это будет 256 корзин, как показано на рис. 8.30.

В целях выполнения квантизации в данном примере сначала определяется диапазон весов с плавающей точкой, который мы обозначаем как $[min, max]$, для минимального и максимального значений. Затем указанный диапазон линейно делится на число корзин (256 в случае 8-битовых целых чисел).

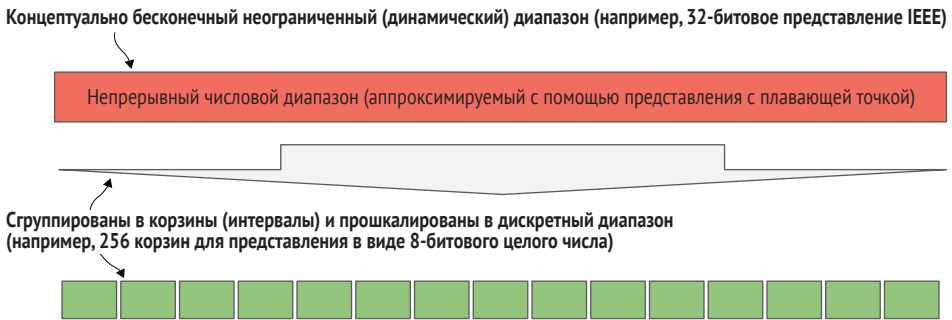


Рис. 8.30 Квантизация категоризует диапазон с плавающей точкой в фиксированный набор корзин, представленных целочисленным типом

В зависимости от аппаратного ускорителя мы можем дополнительно увидеть ускорение выполнения от двух до трех раз на CPU (и TPU). Целочисленные операции на GPU не поддерживаются.

Для GPU, который изначально поддерживает float16 (половинную прецизионность), квантизация выполняется путем конвертирования значений float32 в float16. За счет этого объем памяти модели сокращается вдвое, и исполнение обычно ускоряется в четыре раза.

Кроме того, квантизация работает лучше всего, когда диапазон весов с плавающей точкой ограничен (сжат). В настоящее время для

мобильных моделей для этой цели принято использовать максимальное значение (`max_value`), равное 6.0 для ReLU.

Следует соблюдать осторожность при квантизации очень малых моделей. Крупные модели выигрывают от избыточности весов и невосприимчивы к потере точности при квантизации в 8-битовые целые числа. Мобильные передовые модели были разработаны таким образом, чтобы ограничивать величину потери точности при квантизации. Если мы будем конструировать модели меньшего размера и будем их квантизировать, то их точность может значительно снизиться.

Далее мы рассмотрим TF Lite для исполнения моделей на устройствах с ограниченной памятью.

8.5.2 Конверсия и предсказание с TF Lite

TF Lite – это среда исполнения моделей TensorFlow на устройствах с ограниченным объемом памяти. В отличие от нативной среды исполнения TensorFlow, среда исполнения TF Lite намного меньше, и ее легче разместить на устройствах с ограниченным объемом памяти. Несмотря на то что она оптимизирована под эту цель, она имеет несколько компромиссов. Например, некоторые графовые операции TF не поддерживаются, а иные операции требуют дополнительных шагов. Мы не будем описывать неподдерживаемые графовые операции, но рассмотрим необходимые дополнительные шаги.

Следующий ниже исходный код демонстрирует использование TensorFlow Lite для квантизации существующей модели, где модель представляет собой натренированную модель TF.Keras. Первым шагом является конвертирование модели в формате SavedModel в формат модели TF Lite. Это делается путем инстанцирования библиотечного класса `TFLiteConverter` и передачи ему модели, находящейся прямо в памяти или на диске, в формате сохраненной модели SavedModel, а затем вызова метода `convert()`:

```
import tensorflow as tf  # Создает экземпляр конвертера для модели
                        # TF.Keras (формат SavedModel)
converter = tf.lite.TFLiteConverter.from_saved_model(model)  # ←
tflite_model = converter.convert()  # ← Конвертирует модель в формат TF Lite
```

Версия TF Lite модели не имеет формата сохраненной модели TensorFlow. Не получится использовать напрямую такие методы, как `predict()`. Вместо этого используется интерпретатор TF Lite. Сначала необходимо настроить интерпретатор под модель TF Lite следующим образом:

- 1 инстанцировать интерпретатор TF Lite для модели TF Lite;
- 2 проинструктировать интерпретатор выделить входные и выходные тензоры для модели;

- 3 получить подробную информацию о входных и выходных тензорах модели, которые необходимо знать для предсказания.

Следующий ниже исходный код демонстрирует эти шаги:

```

                                Инстанцирует интерпретатор для модели TF Lite
interpreter = tf.lite.Interpreter(model_content=tf.lite_model)
                                ←
interpreter.allocate_tensors()

input_details = interpreter.get_input_details()
output_details = interpreter.get_output_details()
input_shape = input_details[0]['shape']
                                Получает подробности
                                входного и выходного тензоров,
                                необходимые для предсказания

Выделяет входной и выходной тензоры для модели
```

Входные и выходные данные возвращаются в виде списка; число элементов соответствует числу входных и выходных тензоров. Например, модель с одним входом (например, изображение) и одним выходом (мультиклассовый классификатор) будет иметь один элемент как для входного, так и для выходного тензоров.

Каждый элемент содержит словарь с соответствующими подробностями. В случае входного тензора ключ `shape` возвращает кортеж, который является входной формой. Например, если бы модель принимала на входе изображения (32, 32, 3) (например, CIFAR-10), то ключ вернул бы (32, 32, 3).

В целях выполнения одного предсказания делается следующее.

- 1 Подготовить входные данные для пакета размером 1. Для нашего примера с CIFAR-10 они были бы (1, 32, 32, 3).
- 2 Назначить пакет входному тензору.
- 3 Вызвать интерпретатор для выполнения предсказания.
- 4 Получить выходной тензор из модели (например, выходы `softmax` в мультиклассовой модели).

Следующий ниже исходный код демонстрирует эти шаги:

```

import numpy as np

data = np.expand_dims(x_test[1], axis=0)
                                Конвертирует одиночный вход
                                в пакет размером 1

interpreter.set_tensor(input_details[0]['index'], data)
                                Назначает пакет
                                входному тензору

Получает
выход из
модели
                                ←
interpreter.invoke()
                                Исполняет (вызывает) интерпретатор
                                для выполнения предсказания

softmax = interpreter.get_tensor(output_details[0]['index'])

label = np.argmax(softmax)
                                ←
                                Мультиклассовый пример, определить
                                метку, предсказанную на выходе из softmax
```

Для пакетного предсказания необходимо модифицировать (изменить размер) входной и выходной тензоры интерпретатора под размер пакета. Следующий ниже исходный код изменяет размер пакета для интерпретатора на 128 под вход (32, 32, 3) (CIFAR-10) перед выделением тензоров:

```

# Изменяет размер входного и выходного
# тензоров под пакет размера 128
interpreter = tf.lite.Interpreter(model_content=tflite_model)

interpreter.resize_tensor_input(input_details[0]['index'], (128, 32, 32, 3))
interpreter.resize_tensor_input(output_details[0]['index'], (128, 10))

interpreter.allocate_tensors()
```

Инстанцирует интерпретатор для модели TF Lite

Выделяет входной и выходной тензоры для модели

Резюме

- Переработка с использованием сверток вглубь и утончения сети в MobileNet v1 продемонстрировала возможность выполнять модели на устройствах с ограниченным объемом памяти с точностью модели AlexNet.
- Модернизация остаточного блока в MobileNet v2 в инвертированный остаточный блок еще больше сократила объем памяти и повысила точность.
- SqueezeNet представила концепцию эффективного с точки зрения вычислений макроархитектурного поиска с использованием метапараметров для конфигурирования групповых и блочных атрибутов.
- Переработка и перетасовка каналов в ShuffleNet v1 продемонстрировали возможность выполнения моделей на устройствах с крайне ограниченной памятью, таких как микроконтроллеры.
- Методы квантизации позволили сократить объем памяти на 75 % практически без потери точности предсказательного вывода.
- Применение TF Lite для конвертирования из формата сохраненной модели в квантизированный формат TF Lite и выполнения предсказаний для развертывания на устройствах с ограниченным объемом памяти.

Автокодировщики

Эта глава охватывает следующие ниже темы:

- понимание принципов и шаблонов конструирования глубоких нейросетевых и сверточных нейросетевых автокодировщиков;
- кодирование этих моделей с использованием шаблона процедурного конструирования;
- регуляризация во время тренировки автокодировщика;
- использование автокодировщика для сжатия, устранения шума и сверхразрешающей способности;
- использование автокодировщика для предтренировки с целью улучшения способности модели к обобщению.

Ранее мы обсуждали модели только для контролируемого обучения. *Автокодировщик* как модель относится к категории неконтролируемого обучения. Вспомните, что в контролируемом обучении наши данные состоят из признаков (например, изображений) и меток (например, классов), и мы тренируем модель учиться предсказывать метки из признаков. В неконтролируемом обучении у нас нет меток либо мы их не используем, и мы тренируем модель отыскивать коррелирующие закономерности в данных. Вы, возможно, спросите, а что можно сделать без меток. Сделать можно многое, и автокодировщики – это один из типов модельной архитектуры, который может учиться из непомеченных данных.

Автокодировщики являются фундаментальными моделями глубокого обучения для неконтролируемого обучения. Даже без разметки

человеком автокодировщики могут усваивать сжатие изображений, усваивать представления, устранять шум, генерировать изображения со сверхразрешающей способностью и другие задачи – и мы рассмотрим каждую из них в этой главе.

Так как же неконтролируемое обучение работает с автокодировщиками? Несмотря на то что у нас нет меток для изображений, мы можем манипулировать изображениями, чтобы они были как входными данными, так и выходными метками, и тренировать модель предсказывать выходную метку. Например, выходная метка может быть просто входным изображением – здесь модель будет усваивать функцию тождества (тождественное отображение). Либо мы можем сделать копию изображения и добавить в него шум, а затем использовать зашумленную версию на входе, а изначальное изображение в качестве выходной метки – и наша модель могла бы научиться устранять шум из изображения. В этой главе мы рассмотрим эти и несколько других технических приемов манипулирования входным изображением с целью конвертирования в выходные метки.

9.1 Глубокие нейросетевые автокодировщики

Мы начнем эту главу об автокодировщиках с классической версии глубокой нейронной сети. Хотя можно усваивать интересные вещи, используя только глубокую нейросеть, она плохо масштабируется, когда дело доходит до изображений, поэтому в последующих разделах мы перейдем к использованию сверточных нейросетевых автокодировщиков.

9.1.1 Архитектура автокодировщика

Примером полезности глубоких нейросетевых автокодировщиков является реконструирование изображений. Одной из моих любимых реконструкций, обычно используемой в качестве предлоговой задачи, является мозаичная картинка. В данном случае входное изображение делится на девять плиток, а затем случайным образом перетасовывается. Реконструкционная задача состоит в том, чтобы предсказать порядок, в котором плитки были перетасованы. Поскольку эта задача, по сути, является выводом многозначного регрессора, она хорошо работает с традиционной сверточной нейросетью, где мультиклассовый классификатор заменяется многозначным регрессором.

Автокодировщик состоит из двух базовых компонентов: кодировщика и декодировщика. Для реконструкции изображения кодировщик усваивает оптимальный (или почти оптимальный) метод поступательного сведения данных изображения в латентное пространство, а декодировщик усваивает оптимальный (или почти оптимальный)

метод поступательного разведения латентного пространства с целью реконструирования изображения. Реконструкционная задача определяет тип усвоения представления и усвоения преобразования. Например, в функции тождества реконструкционной задачей является реконструирование входного изображения. Но вы также можете реконструировать изображение без шума (путем устранения шума) или изображение с более высокой разрешающей способностью (сверх-разрешающей способностью). Эти типы реконструкций хорошо работают с автокодировщиком.

Давайте посмотрим, как кодировщики и декодировщики работают вместе в автокодировщике для выполнения такого рода реконструкций. Базовая архитектура автокодировщика, показанная на рис. 9.1, на самом деле состоит из трех ключевых компонентов, при этом латентное пространство располагается между кодировщиком и декодировщиком. Кодировщик выполняет усвоение представления на входе, чтобы усвоить функцию $f(x) = x'$, где x' называется *латентным пространством*, которое является усвоенным представлением из x в более низкой размерности. Затем декодировщик выполняет усвоение преобразования из латентного пространства, чтобы выполнить некоторую форму реконструкции изначального изображения.

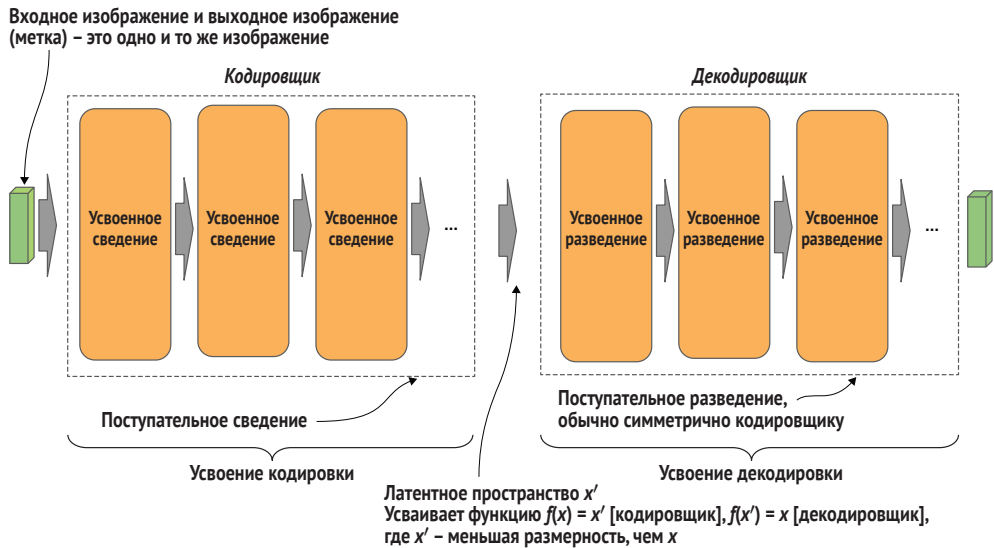


Рис. 9.1 Усвоение функции тождества для входа/выхода в виде изображения в макроархитектуре автокодировщика

Допустим, автокодировщик на рис. 9.1 усваивает функцию тождества $f(x) = x$. Поскольку латентное пространство x' имеет меньшую размерность, мы обычно описываем эту форму автокодировщика как усвоение оптимального способа сжатия изображений в наборе данных (кодировщик), а затем разжатия изображений (декодиров-


```

x = BatchNormalization()(x)
x = ReLU()(x)

return x

```

← Кодировка (латентное пространство)

9.1.3 Декодировщик

Теперь давайте посмотрим на пример имплементации декодировщика в автокодировщике. Опять же, следуя процессу, изображенному на рис. 9.1, мы поступательно разводим число узлов (скрытых единиц) с помощью параметра `layers`. Выходом из декодировщика является реконструированное изображение. Для симметрии с кодировщиком мы прокручиваем параметр `layers` в цикле в обратном направлении. Активационной функцией для заключительного плотного (Dense) слоя является сигмоида (`sigmoid`). Почему? Каждый узел представляет реконструированный пиксел. Поскольку мы нормализовали данные изображения в диапазон между 0 и 1, мы хотим сплющить выходные данные в тот же диапазон между 0 и 1.

Наконец, в целях реконструирования изображения мы выполняем `Reshape`, чтобы реформировать 1-мерный вектор из заключительного плотного слоя в формат изображения ($H \times W \times C$):

```

def decoder(x, layers, input_shape):
    ''' Построить декодировщик
        x : данные на входе в кодировщик (кодировка)
        layers: узлы в расчете на слой
        input_shape: реконструируемая входная форма
    '''
    for _ in range(len(layers)-1, 0, -1):
        n_nodes = layers[_]['n_nodes']
        x = Dense(n_nodes)(x)
        x = BatchNormalization()(x)
        x = ReLU()(x)

        units = input_shape[0] * input_shape[1] * input_shape[2]
        x = Dense(units, activation='sigmoid')(x)

    outputs = Reshape(input_shape)(x)

    return outputs

```

Поступательное разведение единиц (расширение размерности)

Последнее разведение

Реформирует назад во входную форму изображения

← Декодированное изображение

9.1.4 Тренировка

Автокодировщик хочет усваивать представление (которое мы называем латентным пространством) меньшей размерности, а затем усваивать преобразование, чтобы реконструировать изображения в соответствии с заранее определенной задачей; в данном случае функцией тождества.

Следующий ниже пример исходного кода тренирует приведенный выше автокодировщик, чтобы тот усваивал функцию тождества для

набора данных MNIST. В данном примере создается автокодировщик со скрытыми единицами 256, 128, 64 (латентное пространство), 128, 256 и 784 (для реконструкции пикселей).

Как правило, глубокий нейросетевой автокодировщик будет состоять из трех или иногда четырех слоев как в кодировочном компоненте, так и в декодировочном компоненте. Поскольку глубокие нейросети имеют ограниченную эффективность, увеличение емкости, как в слоях, в типичной ситуации не будет улучшать усвоение функции тождества.

Здесь вы видите еще одно традиционное правило глубоких нейросетевых автокодировщиков. Оно заключается в том, что каждый слой в кодировщике сокращает число узлов вдвое, и, наоборот, декодировщик удваивает число узлов, за исключением последнего слоя. Последний слой реконструирует изображение, поэтому число узлов совпадает с числом пикселей во входном векторе; в данном случае 784. Вариант начала с 256 узлов в примере несколько произволен; если не принимать во внимание начало с крупного размера, который будет увеличивать емкость, это поможет мало либо вообще не поможет в улучшении усвоения функции тождества.

Для набора данных мы расширяем форму изображения с (28, 28) до (28, 28, 1), поскольку модели TF.Keras ожидают, что число каналов будет указано явно – даже если имеется только один канал. Наконец, мы тренируем автокодировщик с помощью метода `fit()` и передаем `x_train` как тренировочные данные и как соответствующие метки (функция тождества). Во время оценивания мы аналогичным образом передаем `x_test` как тестовые данные и как соответствующие метки. На рис. 9.2 показан автокодировщик, усваивающий функцию тождества.

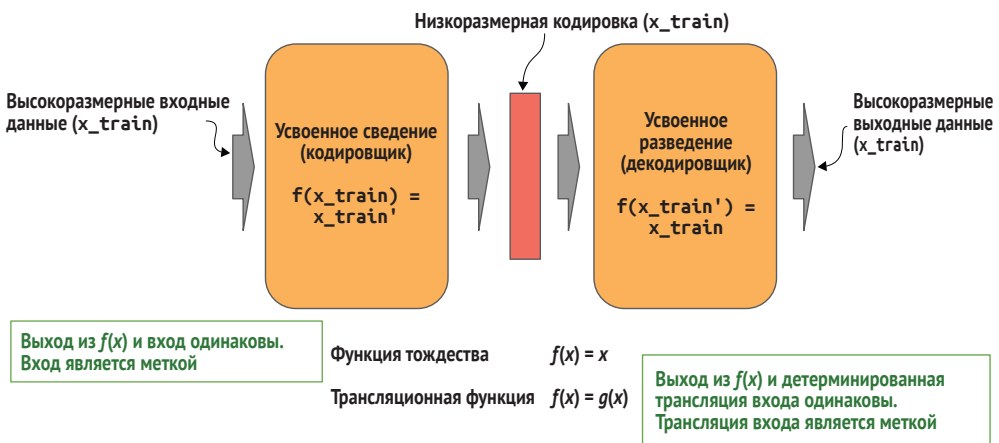


Рис. 9.2 Автокодировщик усваивает две функции: кодировщик учится конвертировать высокоразмерное представление в низкоразмерное представление, а затем декодировщик учится реконструировать обратно в высокоразмерное представление, которое является трансляцией входных данных

Следующий ниже исходный код демонстрирует строительство и тренировку автокодировщика, как показано на рис. 9.2, где тренировочными данными является набор данных MNIST:

```
layers = [ {'n_nodes': 256 }, { 'n_nodes': 128 }, { 'n_nodes': 64 } ] ←
inputs = Input((28, 28, 1)) ← Строит автокодировщик
encoding = encoder(inputs, layers)
outputs = decoder(encoding, layers, (28, 28, 1)) ← Метаметр для числа
ae = Model(inputs, outputs) ← фильтров в расчете на слой

from tensorflow.keras.datasets import mnist
import numpy as np

(x_train, y_train), (x_test, y_test) = mnist.load_data()
x_train = (x_train / 255.0).astype(np.float32)
x_test = (x_test / 255.0).astype(np.float32)
x_train = np.expand_dims(x_train, axis=-1)
x_test = np.expand_dims(x_test, axis=-1) ← Неконтролируемое обучение,
                                         где входные данные и метки
                                         одинаковы

ae.compile(loss='binary_crossentropy', optimizer='adam',
           metrics=['accuracy'])
ae.fit(x_train, x_train, epochs=10, batch_size=32, validation_split=0.1,
      verbose=1) ←
ae.evaluate(x_test, x_test)
```

Давайте подведем итоги. Автокодировщик хочет усваивать представление (латентное пространство) меньшей размерности, а затем усваивать преобразование, чтобы реконструировать изображения в соответствии с предопределенной задачей, такой как функция тождества.

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для глубокого нейросетевого автокодировщика доступна в репозитории на GitHub (<http://mng.bz/JvaK>). Далее мы опишем конструирование и кодирование автокодировщика с использованием сверточных слоев вместо плотных слоев.

9.2 Сверточные автокодировщики

С малыми изображениями в наборах данных MNIST или CIFAR-10 глубокие нейросетевые автокодировщики работают нормально. Но когда мы работаем с крупными изображениями, автокодировщики, использующие узлы (то есть скрытые единицы) для (разведения) сведения, являются дорогостоящими в вычислительном отношении. Для крупных изображений эффективнее глубокие сверточные (DC) автокодировщики. Вместо того чтобы учиться (разводить) сводить узлы, они учатся (разводить) сводить карты признаков. Для этого

в них используются свертки в кодировщике и *развертки*, также именуемые *транспонируемыми свертками*, в декодировщике¹.

В то время как пошаговая свертка, которая выполняет сведение признаков, усваивает оптимальный метод отбора с *пониженной* частотой из распределения, пошаговая развертка (разведение признаков) делает обратное и усваивает опциональный метод отбора с *повышенной* частотой из распределения. Как сведение признаков, так и их разведение показаны на рис. 9.3.




Рис. 9.3. Противопоставление сведения признаков и разведения признаков

Давайте опишем этот процесс, используя тот же контекст, что и для глубокого нейросетевого автокодировщика для MNIST. В данном примере кодировщик и декодировщик имели по три слоя, и кодировщик начинал с 256 карт признаков. Соответствующим эквивалентом для сверточного нейросетевого автокодировщика был бы кодировщик с тремя сверточными слоями соответственно по 256, 128 и 64 фильтра и декодировщик с тремя разверточными слоями соответственно 128, 256 и C , где C – это число каналов на входе.

9.2.1 Архитектура

Макроархитектура для глубокого сверточного автокодировщика может быть разложена следующим образом:

- *стержень* – выполняет выделение признаков грубого уровня;
- *ученик* – выполняет усвоение представления и усвоение преобразования;
- *задача (реконструкция)* – выполняет проекцию и реконструкцию.

На рис. 9.4 показана макроархитектура глубокого сверточного автокодировщика.

¹ Для справки: в переводе приняты следующие противопоставления: сведение (pooling) – разведение (unpooling), свертка (convolution) – развертка (deconvolution), отбор с пониженной частотой (downsampling) – отбор с повышенной частотой (upsampling). – Прим. перев.

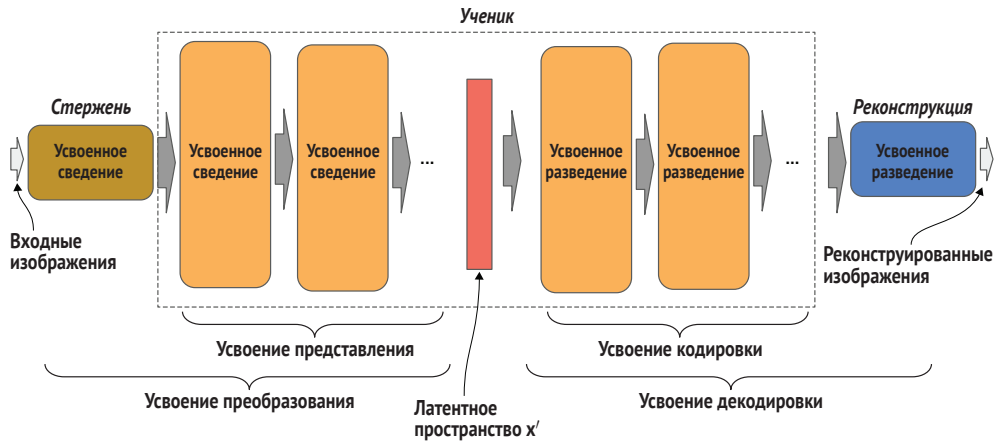


Рис. 9.4 Макроархитектура глубокого сверточного автокодировщика проводит различие между усвоением представления и усвоением преобразования

9.2.2 Кодировщик

Кодировщик в глубоком сверточном автокодировщике (показан на рис. 9.5) поступательно сокращает число карт признаков (посредством сокращения признаков) и размер карт признаков (посредством сведения признаков), используя пошаговые свертки.

Как вы видите, кодировщик поступательно сокращает число фильтров, также именуемых *каналами*, и соответствующий размер. На выходе из кодировщика находится латентное пространство.

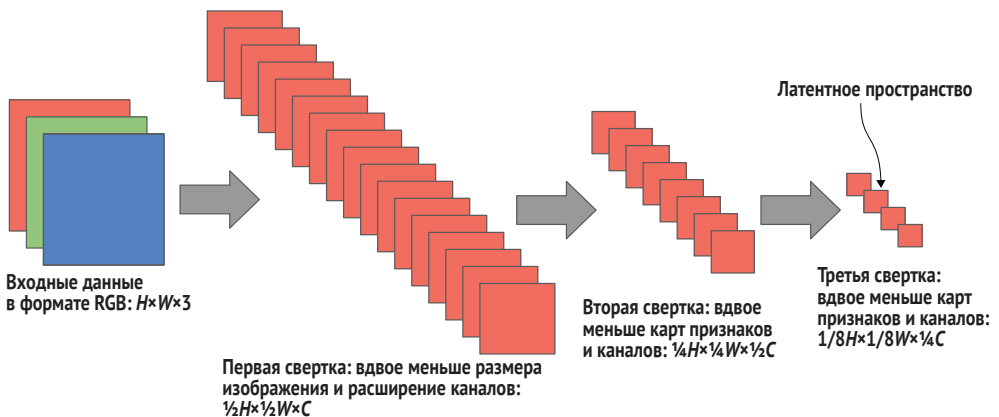


Рис. 9.5 Поступательное сокращение числа и размера выходных карт признаков в сверточном нейросетевом кодировщике

Теперь давайте взглянем на пример имплементации исходного кода кодировщика. Параметр `layers` является списком, в котором число элементов равно числу сверточных слоев, а значение элемента

равно числу фильтров в расчете на свертку. Поскольку мы выполняем поступательное сведение, значение каждого последующего элемента поступательно уменьшается. Вдобавок каждый сверточный слой выполняет дальнейшее сведение карты признаков путем сокращения их размера с шагом 2.

В данной имплементации для свертки мы традиционно используем Conv-BN-RE. Возможно, вы захотите попробовать добиться более высоких результатов, используя BN-RE-Conv.

```
def encoder(inputs, layers):
    """ Построить кодировщик
        inputs : входной вектор
        layers : число фильтров в расчете на слой
    """
    outputs = inputs
    for n_filters in layers:
        outputs = Conv2D(n_filters, (3, 3), strides=(2, 2), padding='same')(outputs)
        outputs = BatchNormalization()(outputs)
        outputs = ReLU()(outputs)
    return outputs
```

Поступательное сведение признаков
(редукция размерности)

Кодировка (латентное пространство)

9.2.3 Декодировщик

Теперь о декодировщике, показанном на рис. 9.6. Декодировщик поступательно увеличивает число карт признаков (посредством расширения признаков) и размер карт признаков (посредством разведения признаков) с помощью пошаговых разверток (транспонированных свертки). Последний слой развертки проецирует карты признаков в соответствии с реконструкционной задачей. В примере с функцией тождества слой будет проецировать карты признаков в форму входных изображений кодировщику.

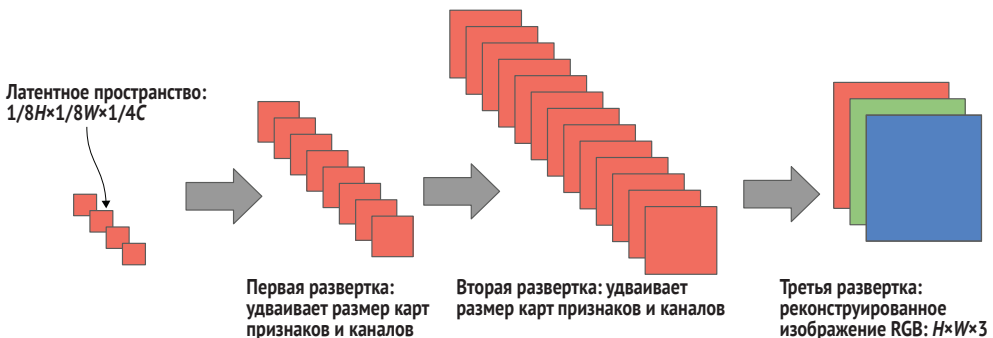


Рис. 9.6 Поступательное расширение числа и размера выходных карт признаков в сверточном нейросетевом декодировщике

Ниже приведена имплементация декодировщика для функции тождества. В данном примере на выходе получается изображение RGB; следовательно, в последней транспонированной свертке имеется три фильтра, каждый из которых соответствует каналу RGB:

```
def decoder(inputs, layers):
    """ Построить декодировщик
        inputs : данные на входе в кодировщик
        layers : число фильтров в расчете на слой (в кодировщике)
    """
    outputs = inputs
    for _ in range(len(layers)-1, 0, -1):
        n_filters = layers[_]
        outputs = Conv2DTranspose(n_filters, (3, 3), strides=(2, 2),
                                  padding='same')(outputs)
        outputs = BatchNormalization()(outputs)
        outputs = ReLU()(outputs)
    outputs = Conv2DTranspose(3, (3, 3), strides=(2, 2), padding='same')(
        outputs)
    outputs = BatchNormalization()(outputs)
    outputs = Activation('sigmoid')(outputs)

    return outputs
```

Поступательное разведение признаков (расширение размерности)

Последнее разведение и восстановление во входную форму изображения

Декодированное изображение

Теперь давайте соберем кодировщик с декодировщиком.

В данном примере сверточные слои будут выполнять поступательное сведение признаков, начиная с 64 фильтров до 32 фильтров и затем до 16, а разверточные слои будут выполнять поступательное разведение, начиная с 32 до 64, а потом 3 для реконструкции изображения. Размер изображения в CIFAR очень мал ($32 \times 32 \times 3$), поэтому если добавить больше слоев, то латентное пространство будет слишком малым для реконструкции, а если мы сделаем слои шире с помощью большего числа фильтров, то рискуем начать запоминать (достигнуть перепогонки) за счет дополнительного параметра емкости.

```
layers = [64, 32, 16]
inputs = Input(shape=(32, 32, 3))
encoding = encoder(inputs, layers)
outputs = decoder(encoding, layers)
model = Model(inputs, outputs)
```

Метапараметр для числа фильтров в расчете на слой в кодировщике

Строит автокодировщик

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для сверточного нейросетевого автокодировщика находится в репозитории на GitHub (<http://mng.bz/JvaK>).

9.3 Разреженные автокодировщики

Размер латентного пространства является компромиссом. Если мы зайдем слишком далеко, то модель может стать переподогнанной к представительному пространству тренировочных данных и не будет обобщать. Если мы будем слишком малы, то это может привести к тому, что мы не сможем выполнить преобразование и реконструкцию для поставленных задач (например, функции тождества).

Мы хотим найти «золотую середину» между ними. Увеличить вероятную возможность, что автокодировщик избежит недоподогнанки и переподгонки, можно путем добавления *ограничения по разреженности*. Концепция ограничения по разреженности состоит в том, чтобы ограничивать активацию нейронов на бутылочном слое, который выдает латентное пространство. Это действует как функция сплющивания, так и как регуляризатор, который помогает автокодировщику обобщать представление латентного пространства.

Ограничение по разреженности обычно описывается как активирование единиц только с крупными активационными значениями и обнуление остальных выходных данных. Другими словами, активации, близкие к нулю, устанавливаются равными нулю (разреженность).

Это можно сформулировать математически следующим образом: мы хотим, чтобы активация любой единицы (σ_i) была ограничена в окрестности среднего активационного значения (σ_μ):

$$\sigma_i \approx \sigma_\mu.$$

Для достижения этой цели мы добавляем штрафной член, который штрафует активацию σ_i , когда она значительно отклоняется от σ_μ .

В TF.Keras ограничение по разреженности добавляется с помощью параметра `activity_regularizer` в последний слой кодировщика. Его значение определяет порог, при котором активация в пределах \pm от нуля меняется на ноль. Типичное значение равно $1e-4$.

Ниже приведена имплементация глубокого сверточного автокодировщика с использованием ограничения по разреженности. Параметр `layers` представляет собой список поступательного сведения числа карт признаков. Мы начинаем с того, что выталкиваем конец списка, то есть последний слой в кодировщике. Затем приступаем к строительству оставшихся слоев. Потом мы используем число карт признаков в вытолкнутом (последнем) слое, чтобы построить последний слой, в который добавляем ограничение по разреженности. Этот последний сверточный слой является латентным пространством:

```
from tensorflow.keras.regularizers import l1
```

```
def encoder(inputs, layers):
    """ Построить кодировщик
        inputs : входной вектор
```

```

layers : фильтров в расчете на слой
"""
outputs = inputs

last_filters = layers.pop() ← Окладывает в сторону последний слой

for n_filters in layers: ← Сведение признаков
    outputs = Conv2D(n_filters, (3, 3), strides=(2, 2), padding='same')
        (outputs)
    outputs = BatchNormalization()(outputs)
    outputs = ReLU()(outputs)

outputs = Conv2D(last_filters, (3, 3), strides=(2, 2), padding='same', ←
        activity_regularizer=l1(1e-4))(outputs)
outputs = BatchNormalization()(outputs)
outputs = ReLU()(outputs) ← Добавляет ограничение по разреженности
                                в последний слой в кодировщике

return outputs

```

9.4 Автокодировщики для устранения шума

Еще один способ использования автокодировщика состоит в его тренировке как устранителя шума из изображений. Мы подаем на вход изображение с шумом, а затем на выходе получаем версию изображения без шума. Думайте об этом процессе как об усвоении функции тождества с некоторым шумом. Если представить этот процесс в виде уравнения, то пусть x – это изображение, а e – шум. Функция учится возвращать x :

$$f(x + e) = x.$$

Для этой цели нам не нужно менять архитектуру автокодировщика; вместо этого мы меняем тренировочные данные. Замена тренировочных данных требует трех базовых шагов:

- 1 строительство генератора случайных чисел, который будет выдавать случайное распределение с диапазоном значений шума, который вы хотите добавлять в тренировочные (и тестовые) изображения;
- 2 во время тренировки добавлять шум в тренировочные данные;
- 3 для меток использовать изначальные изображения.

Ниже приведен исходный код для тренировки автокодировщика устранять шум. Мы задаем шум в пределах нормального распределения с центром 0.5 и со стандартным отклонением 0.5. Затем добавляем распределение случайного шума в копию тренировочных данных (`x_train_noisy`). Мы используем метод `fit()` для тренировки устранителя шума, в котором зашумленные тренировочные данные являются тренировочными, а изначальные (бесшумные) тренировочные данные являются соответствующими метками:

Генерирует шум как нормальное распределение,
центрированное на 0.5 и со стандартным отклонением 0.5

Добавляет шум в копию тренировочных
данных с изображениями

```
noise = np.random.normal(loc=0.5, scale=0.5, size=x_train.shape)
x_train_noisy = x_train + noise
```

```
model.fit(x_train_noisy, x_train, epochs=epochs, batch_size=batch_size,
          verbose=1)
```

Тренирует кодировщик, подавая зашумленные изображения
в качестве тренировочных данных и изначальные изображения
в качестве меток

9.5 Сверхразрешающая способность

Автокодировщики также использовались для разработки моделей генерирования высокой разрешающей способности (super-resolution, аббр. SR). Этот процесс берет снимок с низкой разрешающей способностью (LR) и увеличивает его качество, чтобы улучшить детали снимка до высокой разрешающей способности (HR). Вместо усвоения функции тождества, такой как сжатие, или зашумленной функции тождества, такой как в устранении шума, мы хотим усвоить отображение представления между снимком с низкой разрешающей способностью и снимком с высокой разрешающей способностью. Давайте воспользуемся функцией, чтобы выразить это отображение, которое мы хотим усвоить:

$$f(x_{lr}) = x_{hr}$$

В данном уравнении $f()$ представляет преобразовательную функцию, которая усваивается моделью. Член x_{lr} представляет снимки с низким разрешением на входе в функцию, а член x_{hr} представляет преобразованный предсказанный результат с высоким разрешением на выходе из функции.

Хотя в настоящее время очень продвинутые модели способны генерировать сверхразрешающую способность, в ранних версиях (~2015 г.) использовались вариации автокодировщиков, которые усваивали отображения из представления с низкой разрешающей способностью в представления с высокой разрешающей способностью. Одним из примеров является сверхразрешающая сверточная нейросетевая модель (super-resolution convolutional neural network, аббр. SRCNN), которая была представлена в статье «Сверхразрешающая способность снимков с использованием глубоких сверточных сетей» Чао Донга и соавт. (Image Super-Resolution Using Deep Convolutional Networks, Chao Dong et al., <https://arxiv.org/pdf/1501.00092.pdf>). При таком подходе модель усваивает представление (латентное пространство) снимка с низкой разрешающей способностью в высокоразмерном пространстве. Затем она усваивает отображение из высокоразмерного пространства снимка с низкой разрешающей спо-

способностью в снимок с высокой разрешающей способностью, чтобы реконструировать снимок с высокой разрешающей способностью. Обратите внимание, что это противоположно типичному автокодировщику, который усваивает представление в низкоразмерном пространстве.

9.5.1 Сверхразрешение на основе предотбора с повышенной частотой

Создатели модели SRCNN внедрили применение полностью сверточной нейронной сети для генерирования изображений в сверхразрешающей способности. Этот подход называется подходом сверхразрешением (SR) на основе предотбора с повышенной частотой, изображенным на рис. 9.7. Указанную модель можно разложить на четыре компонента: выделение признаков с низким разрешением, представление с высокой размерностью, кодировщик в представлении с низкой размерностью и сверточный слой для реконструкции.

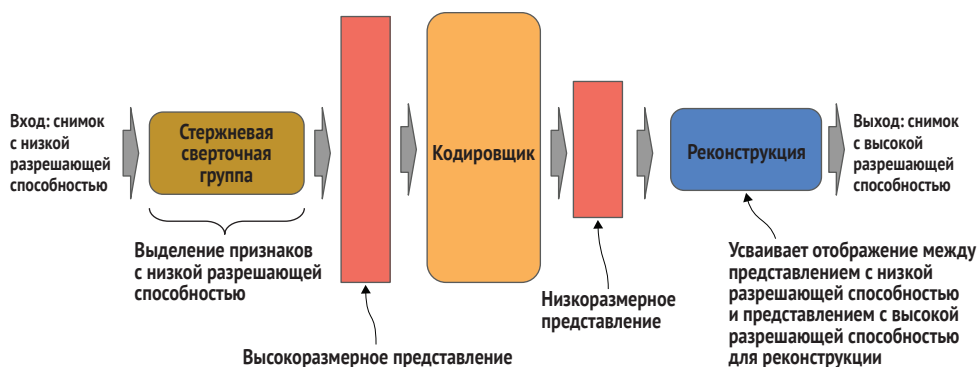


Рис. 9.7 Сверхразрешающая модель на основе предотбора с повышенной частотой учится реконструировать снимок с высоким разрешением из снимка с низким разрешением

Давайте углубимся в детали. В отличие от автокодировщика, в компоненте выделения признаков с низким разрешением нет сведения признаков (или отбора с пониженной частотой). Вместо этого размер карт признаков остается таким же, как размер каналов в снимке с низким уровнем на входе. Например, если входная форма равна (16, 16, 3), то размер карты признаков $H \times W$ останется 16×16 .

В стержневой свертке число карт признаков существенно увеличивается по сравнению с числом каналов (3) на входе, в силу чего мы получаем высокоразмерное представление снимка с низкой разрешающей способностью. Затем кодировщик редуцирует высокоразмерное представление в низкоразмерное представление. Заключительная свертка реконструирует изображение как изображение с высокой разрешающей способностью.

В типичной ситуации вы бы применили этот подход к сверхразрешающей (SR) модели, используя существующий набор снимков, который становится изображениями с высокой разрешающей способностью. Затем вы делаете копию тренировочных данных, в которых размер каждого изображения был уменьшен, а затем возвращен к изначальному размеру. Для того чтобы выполнить оба изменения размера, вы используете статический алгоритм, такой как бикубическая интерполяция. Изображения с низкой разрешающей способностью будут того же размера, что и изображения с высокой разрешающей способностью, но из-за аппроксимаций, сделанных во время операций изменения размера, изображения с низкой разрешающей способностью будут иметь более низкое качество, чем изначальные изображения.

Что же такое интерполяция и, конкретнее, *бикубическая интерполяция*? Подумайте о ней так: если у нас есть 4 пиксела и мы заменяем их 2 пикселами или наоборот, то вам нужен математический метод, который дает хорошую оценку для представления замены, – это и есть *интерполяция*. *Кубическая интерполяция* – это особый метод выполнения описанного выше с (1-мерным) вектором, а *бикубическая* – это вариация, используемая для (2-мерной) матрицы. Бикубическая интерполяция, как правило, дает более оптимальную оценку для редукции изображения, чем другие алгоритмы интерполяции.

Ниже приведен пример исходного кода, демонстрирующий подготовку тренировочных данных с использованием набора данных CIFAR-10. В данном примере массив NumPy `x_train` содержит тренировочные изображения. Затем мы создаем зеркальный список `x_train_lr` для пар с низкой разрешающей способностью, последовательно сначала изменяя размер каждого изображения в `x_train` до половины $H \times W$ (16, 16) и затем изменяя размер изображения обратно в изначальное $H \times W$ (32, 32) и помещая его в то же индексное местоположение в `x_train_lr`. Наконец, мы нормализуем пиксельные данные в обоих наборах изображений:

```
from tensorflow.keras.datasets import cifar10
import numpy as np
import cv2

(x_train, y_train), (x_test, y_test) = cifar10.load_data()

x_train_lr = []
for image in x_train:
    image = cv2.resize(image, (16, 16), interpolation=cv2.INTER_CUBIC)
    x_train_lr.append(cv2.resize(image, (32, 32),
                                interpolation=cv2.INTER_CUBIC))
x_train_lr = np.asarray(x_train_lr)

x_train = (x_train / 255.0).astype(np.float32)
x_train_lr = (x_train_lr / 255.0).astype(np.float32)
```

Скачивает в память набор данных CIFAR-10 в виде изображений с высокой разрешающей способностью

Создает низкоразрешающие пары среди тренировочных изображений

Нормализует пиксельные данные для тренировки

Теперь давайте рассмотрим исходный код для сверхразрешающей модели на основе предобора с повышенной частотой для реконструкции сверхразрешающего качества на малых изображениях, таких как CIFAR-10. В целях ее тренировки мы трактуем изначальные изображения CIFAR-10 32×32 (`x_train`) как изображения с высокой разрешающей способностью, а зеркальные парные изображения (`x_train_lr`) – как изображения с низкой разрешающей способностью. С целью тренировки изображения с низкой разрешающей способностью подаются на вход, а парные изображения с высокой разрешающей способностью используются как соответствующие метки.

Этот пример дает довольно хорошие результаты реконструкции на CIFAR-10 всего за 20 эпох с точностью реконструкции 88 %. Как можно видеть в исходном коде, стержневой компонент `stem()` выполняет выделение признаков с низкой разрешающей способностью, используя грубый фильтр 9×9 , и выдает 64 карты признаков для высокоразмерного представления. Кодировщик `encoder()` состоит из свертки для сокращения низкоразмерного представления из высокой в низкую размерность, используя бутылочную свертку 1×1 и сокращая число карт признаков до 32. Окончательная свертка с использованием грубого фильтра 5×5 усваивает отображение из представления с низкой разрешающей способностью в представление с высокой разрешающей способностью для реконструкции:

```
from tensorflow.keras import Input, Model
from tensorflow.keras.layers import Conv2D, BatchNormalization
from tensorflow.keras.layers import ReLU, Conv2DTranspose, Activation
from tensorflow.keras.optimizers import Adam

def stem(inputs):  ←———— Выделение признаков с низкой разрешающей способностью
    x = Conv2D(64, (9, 9), padding='same')(inputs)
    x = BatchNormalization()(x)
    x = ReLU()(x)
    return x
    |
    | Высокоразмерное
    | представление

def encoder(x):
    x = Conv2D(32, (1, 1), padding='same')(x)
    x = BatchNormalization()(x)
    x = ReLU()(x)
    x = Conv2D(3, (5, 5), padding='same')(x)
    x = BatchNormalization()(x)
    outputs = Activation('sigmoid')(x)
    return outputs
    |
    | Бутылочная свертка 1×1
    | в качестве кодировщика

    |
    | Свертка 5×5 для реконструкции
    | в изображение с высокой
    | разрешающей способностью

inputs = Input((32, 32, 3))
x = stem(inputs)
outputs = encoder(x)

model = Model(inputs, outputs)
model.compile(loss='mean_squared_error', optimizer=Adam(lr=0.001),
              metrics=['accuracy'])
```

```
model.fit(x_train_lr, x_train, epochs=25, batch_size=32, verbose=1,
        validation_split=0.1)
```

Теперь давайте посмотрим на несколько реальных снимков. На рис. 9.8 показан набор одинаковых снимков павлина из тренировочных данных CIFAR-10. Первые два снимка – это пара с низкой и высокой разрешающей способностью, используемая при тренировке, а третье – реконструкция того же изображения павлина в сверхразрешающей способности после тренировки модели. Обратите внимание, что на снимке с низкой разрешающей способностью больше артефактов – квадратных областей, без плавных цветовых переходов вокруг контуров, – чем на изображении с высокой разрешающей способностью. Реконструированное изображение в сверхразрешающей способности показывает более плавный переход цвета вокруг контуров, аналогичный изображению с высокой разрешающей способностью.




Рис. 9.8 Сравнение пар снимков с низкой и высокой разрешающей способностью и реконструированного снимка в сверхразрешении (SR) для метода SR с предотбором с повышенной частотой

9.5.2 Сверхразрешение на основе постотбора с повышенной частотой

Еще одним примером модели в стиле SRCNN является сверхразрешающая (SR) модель на основе постотбора с повышенной частотой, изображенная на рис. 9.9. Указанную модель можно разложить на три компонента: выделение признаков с низкой разрешающей способностью, высокоразмерное представление и декодирующий для реконструкции.

Давайте углубимся в детали. Опять же, в отличие от автокодировщика, в компоненте выделения признаков с низкой разрешающей способностью нет сведения признаков (или отбора с пониженной частотой). Вместо этого размер карт признаков остается таким же, как и размер каналов в изображении с низким уровнем на входе. Например, если входная форма равна (16, 16, 3), то $H \times W$ карт признаков останется 16×16.

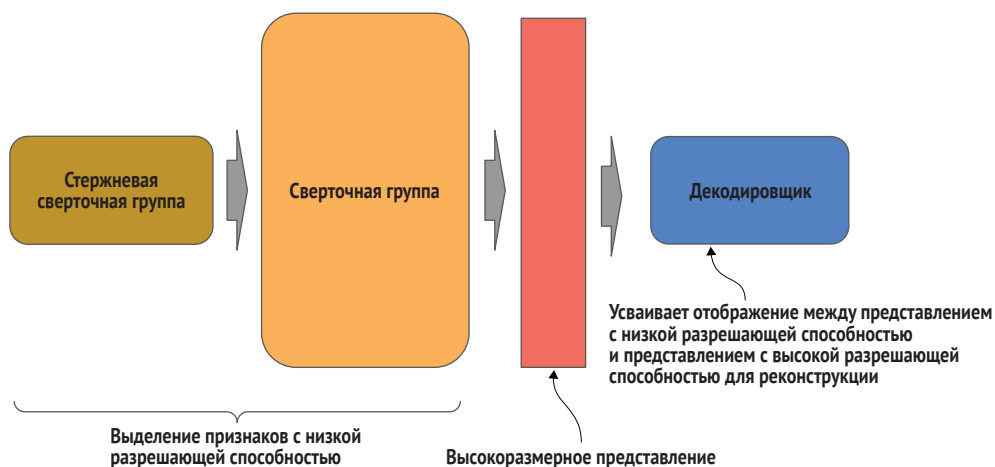


Рис. 9.9 Сверхразрешающая (SR) модель на основе постотбора с повышенной частотой

Во время свертки мы поступательно увеличиваем число карт признаков – именно там мы получаем высокоразмерное пространство. Например, мы могли бы перейти от трехканальных данных на входе к 16, затем 32, а потом 64 картам признаков. И вы, возможно, спросите, зачем нужна более высокая размерность. Мы хотим, чтобы обилие разных представлений выделения признаков с низкой разрешающей способностью помогало нам усваивать отображение из них в высокую разрешающую способность, чтобы иметь возможность выполнять реконструкцию с использованием развертки. Но если у нас слишком много карт признаков, то мы можем подвергнуть модель запоминанию отображений в тренировочных данных.

В типичной ситуации мы тренируем сверхразрешающую (SR) модель, используя существующий набор снимков, который будет снимками с высокой разрешающей способностью, а затем делаем копию тренировочных данных, в которых размер каждого изображения был уменьшен для пар снимков с низкой разрешающей способностью.

Следующий ниже пример исходного кода демонстрирует подготовку тренировочных данных с использованием набора данных CIFAR-10. В этом примере массив `NumPy x_train` содержит тренировочные снимки. Затем мы создаем зеркальный список `x_train_lr` для пар с низкой разрешающей способностью, последовательно изменяя размер каждого изображения в `x_train` и размещая его в том же индексном местоположении в `x_train_lr`. Наконец, мы нормализуем пиксельные данные в обоих наборах снимков.

В случае постотбора с повышенной частотой размер снимков с низкой разрешающей способностью остается 16×16 и не изменяется обратно в 32×32 , как это было в случае предотбора с повышенной частотой; при этом более низкая разрешающая способность была внедрена потерей пиксельной информации посредством статической интерполяции во время изменения размера обратно в 32×32 .

```

from tensorflow.keras.datasets import cifar10
import numpy as np
import cv2

(x_train, y_train), (x_test, y_test) = cifar10.load_data()

x_train_lr = []
for image in x_train:
    x_train_lr.append(cv2.resize(image, (16, 16),
                                interpolation=cv2.INTER_CUBIC))
x_train_lr = np.asarray(x_train_lr)

x_train = (x_train / 255.0).astype(np.float32)
x_train_lr = (x_train_lr / 255.0).astype(np.float32)

```

Скачивает в память набор данных CIFAR-10 в качестве снимков с высокой разрешающей способностью

Создает пары с низкой разрешающей способностью в тренировочных снимках

Нормализует пиксельные данные для тренировки

Ниже приведена имплементация исходного кода свёрхразрешающей (SR) модели на основе постотбора с повышенной частотой, которая обеспечивает хорошее качество реконструкции высокой разрешающей способности на малых снимках, таких как в CIFAR-10. Мы закодировали эту имплементацию специально для CIFAR-10. В целях ее тренировки мы трактуем изначальные снимки CIFAR-10 32×32 (x_{train}) как снимки с высокой разрешающей способностью, а зеркальные парные снимки ($x_{\text{train_lr}}$) – как снимки с низкой разрешающей способностью. С целью тренировки изображения с низкой разрешающей способностью подаются на вход, а парные снимки с высокой разрешающей способностью используются как соответствующие метки.

Этот пример дает довольно хорошие результаты реконструкции на CIFAR-10 всего за 20 эпох с точностью реконструкции 90 %. В данном примере стержневой компонент `stem()` и ученический компонент `learner()` выполняют выделение признаков с низкой разрешающей способностью и поступательно расширяют размерность карт признаков с 16, 32, а затем до 64 карт признаков. Результатом последней свёртки из 64 карт признаков является высокоразмерное представление. Декодировщик `decoder()` состоит из развертки для усвоения отображения из представления с низкой разрешающей способностью в представление с высокой разрешающей способностью для реконструкции:

```

from tensorflow.keras import Input, Model
from tensorflow.keras.layers import Conv2D, BatchNormalization
from tensorflow.keras.layers import ReLU, Conv2DTranspose, Activation
from tensorflow.keras.optimizers import Adam

def stem(inputs):
    x = Conv2D(16, (3, 3), padding='same')(inputs)
    x = BatchNormalization()(x)
    x = ReLU()(x)
    return x

def learner(x):
    x = Conv2D(32, (3, 3), padding='same')(x)

```

Выделение признаков с низкой разрешающей способностью

```

x = BatchNormalization()(x)
x = ReLU()(x)
x = Conv2D(64, (3, 3), padding='same')(x)
x = BatchNormalization()(x)
x = ReLU()(x)
return x

```

Высокоразмерное представление

Реконструкция из низкой разрешающей способности в высокую

```

def decoder(x):
    x = Conv2DTranspose(3, (3, 3), strides=2, padding='same')(x)
    x = BatchNormalization()(x)
    x = Activation('sigmoid')(x)
    return x

inputs = Input((16, 16, 3))

x = stem(inputs)
x = learner(x)
outputs = decoder(x)

model = Model(inputs, outputs)
model.compile(loss='binary_crossentropy', optimizer=Adam(lr=0.001),
              metrics=['accuracy'])
model.fit(x_train_lr, x_train, epochs=25, batch_size=32, verbose=1,
        validation_split=0.1)

```

Давайте вернемся к тем же снимкам павлинов, к которым мы обращались ранее. На рис. 9.10 первые два снимка представляют пару с низкой и высокой разрешающей способностью, использованную при тренировке, а третий представляет реконструкцию того же снимка павлина в сверхразрешении после тренировки модели. Как и в предыдущей сверхразрешающей (SR) модели на основе предотбора с повышенной частотой, сверхразрешающая модель на основе постотбора с повышенной частотой произвела реконструированный снимок в сверхразрешении с меньшим числом артефактов, чем снимок с низкой разрешающей способностью.




Рис. 9.10 Сравнение пары снимков с низкой разрешающей и высокой разрешающей способностью и реконструированного снимка в сверхразрешении для метода SR на основе постотбора с повышенной частотой

Полная версия исходного кода с применением шаблона идиоматического конструирования на основе процедурного реиспользования для SRCNN доступна в репозитории на GitHub (<http://mng.bz/w0a2>).

9.6 Предлоговые задачи

Как мы уже обсуждали, автокодировщики можно тренировать без меток, чтобы они учились извлекать существенные признаки, которые мы можем переориентировать за рамки приведенных до сих пор примеров: сжатия и устранения шума.

Что мы подразумеваем под существенными признаками? Говоря о визуализации, мы хотим, чтобы наши модели усваивали существенные признаки данных, а не сами данные. Это позволяет моделям не только обобщать незнакомые данные в одном и том же распределении, но и лучше предсказывать, когда происходит сдвиг во входном распределении после развертывания модели.

Например, предположим, что у нас есть модель, натренированная распознавать самолеты, и снимки, использованные при тренировке, состояли из самых разнообразных сцен, в том числе на летном поле, при подруливании к терминалу и в воздухе, но ни один из них не был в ангаре. Если после развертывания модели теперь она видит самолеты в ангаре, то у нас есть изменение в распределении входных данных; такое изменение называется *дрейфом данных*. И когда появляется снимок самолета в ангаре, мы получаем меньшую точность.

В этом примере мы могли бы попытаться улучшить модель путем ее перетренировки дополнительными снимками, содержащими самолеты в ангаре. Великолепно, теперь она работает после развертывания. Но предположим, что новая модель видит самолеты с другим фоном, на котором она не тренировалась, например самолеты на воде (гидросамолеты), самолеты на песке на кладбище самолетов, самолеты, частично собранные на заводе. Ведь в реальном мире всегда есть что-то, чего вы не ожидаете!

И именно поэтому важно усваивать существенные признаки набора данных, а не сами данные. Для того чтобы автокодировщики работали как надо, они должны усваивать характер коррелирования пикселей, то есть усваивать представление. Чем больше корреляция, тем больше возможности для того, чтобы появилась взаимосвязь в представлении латентного пространства, и чем меньше корреляция, тем больше возможности для того, что она не появится.

Здесь мы не будем подробно останавливаться на предтренировке с предловыми задачами¹, но кратко коснемся этого в контексте автокодировщика. Для наших целей мы хотим использовать автокодировочный подход для тренировки стержневой сверточной группы, чтобы научиться извлекать существенные признаки грубого уровня,

¹ В оригинале pretext task – предлоговая задача. – Прим. перев.

перед тем как тренировать модель на наборе данных. Вот соответствующие шаги.

- 1 Провести разминочную (контролируемую) тренировку на целевой модели для численной стабилизации (впоследствии обсуждается в главе 14).
- 2 Построить автокодировщик, состоящий из стержневой группы модели в качестве кодировщика и инвертированной стержневой группы в качестве декодировщика.
- 3 Перенести численно стабилизированные веса из целевой модели в кодировщик в автокодировщике.
- 4 Натренировать (неконтролируемо) автокодировщик на предлоговой задаче (например, сжатия, устранения шума).
- 5 Перенести натренированные веса целевой задачи из кодировщика автокодировщика в целевую модель.
- 6 Натренировать (контролируемо) целевую модель.

На рис. 9.11 показаны эти этапы.

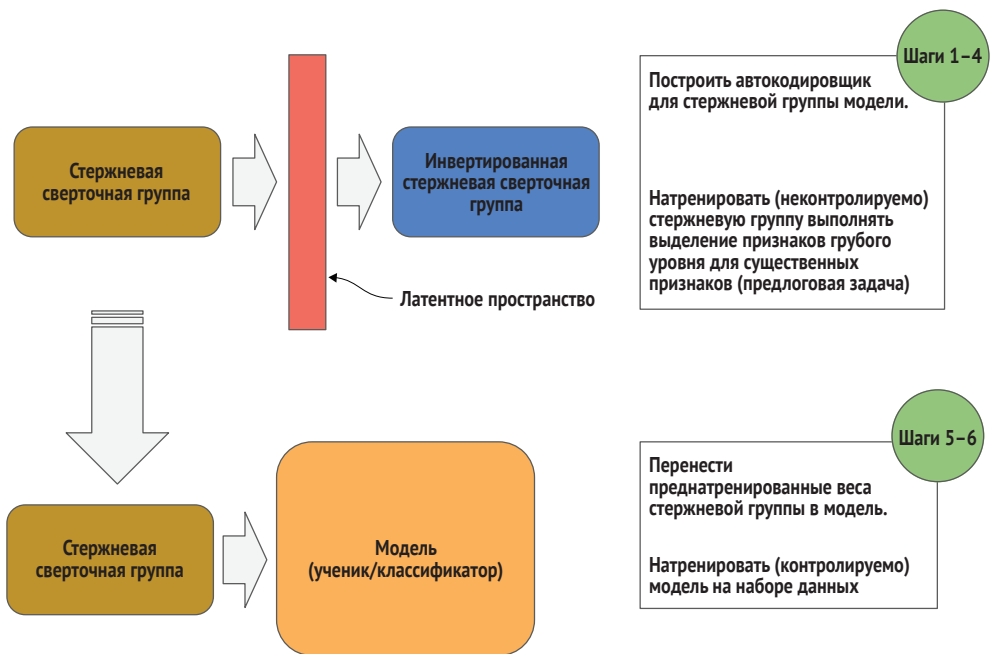


Рис. 9.11 Предварительная тренировка стержневой группы с использованием автокодировщика для улучшения обобщения на незнакомых данных, когда модель полностью натренирована с использованием помеченных данных

Давайте рассмотрим еще одну часть этой формы предлоговой задачи. У вас может возникнуть мысль, что данные на выходе из стержневой сверточной группы будут больше данных на входе. В то время как мы выполняем статическое или признаковое сведение на каналах, мы увеличиваем число совокупных каналов. Например, мы

могли бы использовать сведение, чтобы сократить размер каналов до 25 % или даже до 6 %, но мы увеличиваем число каналов с трех (RGB) до примерно 64.

Таким образом, латентное пространство теперь больше данных на входе и гораздо более подвержено перепогонке. Для этой конкретной цели мы строим разреженный автокодировщик, чтобы компенсировать потенциальную перепогонку.

Ниже приведен пример имплементации. Хотя мы не обсуждали слой отбора с повышенной частотой `UpSampling2D`, он является обратным по отношению к слою пошагового максимального сведения `MaxPooling2D`. Вместо использования статического алгоритма уменьшения высоты и ширины вдвое он использует статический алгоритм увеличения высоты и ширины в 2 раза:

```
from tensorflow.keras import Input, Model
from tensorflow.keras.layers import Conv2D, Conv2DTranspose
from tensorflow.keras.layers import MaxPooling2D, UpSampling2D
from tensorflow.keras.regularizers import l1

def stem(inputs):
    x = Conv2D(64, (5, 5), strides=(2, 2), padding='same',
              activity_regularizer=l1(1e-4))(inputs)
    x = MaxPooling2D((2, 2), strides=(2, 2))(x)
    return x

def inverted_stem(inputs):
    x = UpSampling2D((2, 2))(inputs)
    x = Conv2DTranspose(3, (5, 5), strides=(2, 2), padding='same')(x)
    return x

inputs = Input((128, 128, 3))
_encoder = stem(inputs)
_decoder = inverted_stem(_encoder)
model = Model(inputs, _decoder)
```

Фильтр 5×5 для выделения грубых признаков с помощью сведения признаков

Использует максимальное сведение, чтобы сократить карты признаков до 6 % от размера изображения

Инвертирует сведение признаков и реконструирует изображение

Инвертирует максимальное сведение

Ниже приведена сводная информация из метода `summary()` для данного автокодировщика. Обратите внимание, что входной размер равен выходному размеру:

Layer (type)	Output Shape	Param #
input_4 (InputLayer)	[(None, 128, 128, 3)]	0
conv2d_2 (Conv2D)	(None, 64, 64, 64)	4864
max_pooling2d_1 (MaxPooling2D)	(None, 32, 32, 64)	0
up_sampling2d (UpSampling2D)	(None, 64, 64, 64)	0
conv2d_transpose (Conv2DTran)	(None, 128, 128, 3)	4803

Total params: 9,667
Trainable params: 9,667
Non-trainable params: 0

9.7 За пределами компьютерного зрения: последовательность к последовательности

Давайте кратко рассмотрим базовую архитектуру модели естественно-языковой обработки, именуемую *последовательностью к последовательности* (sequence-to-sequence, аббр. Seq2Seq). Этот тип модели включает в себя как понимание естественного языка (NLU) – понимание текста, так и генерацию естественного языка (NLG) – генерирование нового текста. Для генерации естественного языка модель Seq2Seq может выполнять такие функции, как перевод с языка на язык, резюмирование документов, а также вопросы и ответы. Например, чат-боты – это модели Seq2Seq, которые задают вопросы и отвечают на них.

В конце главы 5 мы представили архитектуру модели понимания ЕЯ (NLU) и увидели, насколько компонентная конструкция сопоставима с компьютерным зрением. Мы также рассмотрели механизм внимания, который сопоставим с отождествляющей связью в остаточной сети. Чего мы не рассмотрели, так это модельной архитектуры трансформера, авторы которой в 2017 году ввели механизм внимания. Это нововведение превратило понимание ЕЯ из решения, основанного на временных рядах с использованием рекуррентной нейросети, в пространственную задачу. В рекуррентной нейросети модель могла просматривать только по одному фрагменту входного текста за раз и удерживать порядок. Вдобавок с каждым фрагментом модель должна была поддерживать в памяти важные признаки. Это добавляло сложности в конструкцию модели в том смысле, что в графе требовались циклы, чтобы имплементировать удержание ранее встречавшихся признаков. Благодаря трансформеру и механизму внимания модель смотрит на текст одним взглядом.

На рис. 9.12 показана модельная архитектура трансформера, в которой имплементирована модель Seq2Seq.

Как вы видите, учебный компонент состоит из кодировщика для понимания ЕЯ (NLU) и из декодировщика для генерации ЕЯ (NLG). Вы тренируете модель, используя текстовые пары, предложения, абзацы и т. п. Например, если вы тренируете чат-бот для вопросов и ответов, то входными данными будут вопросы, а метками – ответы. Для резюмирования документов входными данными будет текст, меткой – резюме.

В трансформерной модели кодировщик последовательно усваивает редукцию размерности контекста входных данных, что сопоста-

вимо с усвоением представления кодировщиком в автокодировщике компьютерного зрения. Выход из кодировщика называется *промежуточным представлением*, сопоставимым с латентным пространством в автокодировщике компьютерного зрения.

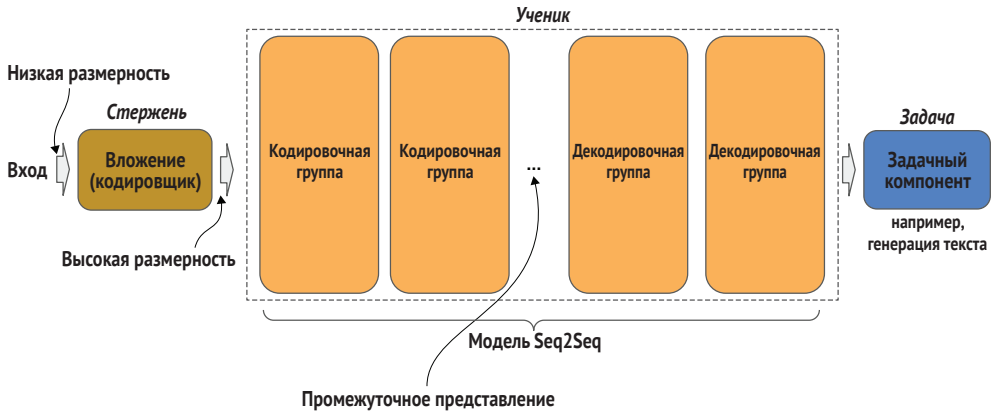


Рис. 9.12 Архитектура трансформера состоит из кодировщика для понимания ЕЯ (NLU) и из декодировщика для генерации ЕЯ (NLG)

Декодировщик последовательно усваивает расширение размерности промежуточного представления в преобразованный контекст, что сравнимо с усвоением преобразования декодировщиком в автокодировщике компьютерного зрения.

Данные на входе в декодировщик передаются задачному компоненту, который усваивает генерацию текста. Задача генерации текста сопоставима с задачей реконструкции в автокодировщике компьютерного зрения.

Резюме

- Автокодировщик усваивает оптимальное отображение входных данных в низкоразмерное представление, а затем усваивает отображение обратно в высокоразмерное представление, чтобы иметь возможность выполнять преобразовательную реконструкцию изображения.
- Примеры преобразовательных функций, которые автокодировщик может усваивать, включают функцию тождества (сжатие), устранения шума в изображении и строительство изображения с более высокой разрешающей способностью.
- В сверточном нейросетевом автокодировщике сведение выполняется с помощью пошаговой свертки, а разведение – с помощью пошаговой развертки.

- Использование автокодировщика в неконтролируемом обучении может тренировать модель усваивать существенные признаки распределения набора данных без меток.
- Использование кодировщика в качестве предстержня с предлоговой задачей неконтролируемого обучения помогает в последующем контролируемом обучении, чтобы усваивать существенные признаки для более качественного обобщения.
- В модельном шаблоне Seq2Seq для понимания естественного языка (NLU) используются кодировщик и декодировщик, сопоставимые с автокодировщиком.

Часть III

Работа с конвейерами

В третьей части вы научитесь конструировать и строить производственные конвейеры для тренировки моделей, их развертывания и обслуживания запросов на предсказание. Мы начнем с того, что познакомим вас с принципом работы гиперпараметрической настройки под капотом, а затем покажем вам самодельный метод, а также автоматическую гиперпараметрическую настройку с помощью настройщика KerasTuner. В обоих случаях при выборе пространства поиска эффективная гиперпараметрическая настройка требует здравого суждения, поэтому мы обсудим соответствующие рекомендации.

Далее мы переходим к переносу обучения. В переносе обучения (трансферном обучении) веса из другой натренированной модели реиспользуются, и новая модель настраивается с меньшим объемом данных и меньшим временем тренировки. Мы рассмотрим несколько вариантов переноса обучения, один для случаев, когда предметная область нового набора данных очень похожа на предметную область натренированной модели (например, овощи и фрукты), а другой – когда такая область сильно отличается. Наконец, мы рассмотрим методы переноса предметной области для инициализации моделей при выполнении полной тренировки.

В оставшихся главах мы глубоко погрузимся в весь конвейер производственного уровня. Мы начнем с концепций, лежащих в основе распределений данных, и с того, как они влияют на способность развернутой модели обобщать на входные данные реального мира, которые не встречались во время тренировки. Вы изучите технические приемы тренировки модели, направленные на улучшение обобщения. Далее мы углубляемся в компоненты, конструкцию и конфигурацию конвейера данных, охватывая складирование данных, про-

цесс извлечения-преобразования-загрузки данных (ETL) и подачу данных в модели. Вы научитесь кодировать эти конвейеры различными способами, используя TF.Keras, tf.data, TFRecords и TensorFlow Extended (TFX).

Наконец, мы собираем все это воедино и показываем то, как конвейер распространяется на тренировку, далее на развертывание, а затем на обслуживание производственных запросов. Вы увидите информацию об аппаратных ресурсах для развертывания, таких как симулированные производственные среды («песочницы»), балансировка нагрузки и автоматическое масштабирование. В процессе обслуживания вы научитесь обслуживать запросы из облака, используя предварительно построенные и конкретно-прикладные контейнеры, а также из периферии, и познакомитесь с деталями развертывания в производстве и A/B-тестирования.

10

Гиперпараметрическая настройка

Эта глава охватывает следующие ниже темы:

- инициализация весов в модели перед разминочной тренировкой;
- выполнение гиперпараметрического поиска вручную и автоматически;
- строительство планировщика скорости усвоения для тренировки модели;
- регуляризация модели во время тренировки.

Гиперпараметрическая настройка – это процесс поиска оптимальных настроек тренировочных гиперпараметров с целью *минимизировать время тренировки и максимизировать точность на тестовых данных*. Обычно эти два целевых критерия невозможно оптимизировать полностью. Если мы сведем к минимуму время тренировки, то, скорее всего, не добьемся наилучшей точности. И наоборот, если сведем к минимуму тестовую точность, то нам, скорее всего, потребуется больше времени для тренировки.

Настройка – это поиск комбинации гиперпараметрических значений, которые соответствуют вашим ориентировочным показателям целевых критериев. Например, если ваш расчетный показатель – максимально возможная точность, то вы можете не беспокоиться о минимизации времени тренировки. В другой ситуации, если вам нужна только хорошая (но не лучшая) точность и вы постоянно выполняете перетренировку, то вы, возможно, захотите найти настройки, которые обеспечивают эту хорошую точность, при этом минимизируя время тренировки.

Как правило, целевой критерий не имеет определенного набора настроек. Вероятнее всего, что в пространстве поиска ваш целевой критерий будет достигнут различными наборами настроек. Вам нужно найти только один из этих наборов – и это то, чем является настройка.

Теперь следующий вопрос: какие гиперпараметры настраивать? Мы рассмотрим их в этой главе подробно, но в сущности это параметры, которые направляют тренировку модели в сторону максимального достижения целевого критерия. В данной главе мы будем настраивать следующие параметры: размер пакета, скорость усвоения и планировщики скорости усвоения.

В этой главе мы рассмотрим несколько широко используемых технических приемов гиперпараметрического поиска (настройки). На рис. 10.1 показан совокупный гиперпараметрический процесс в традиционной производственной среде. Пока не беспокойтесь о деталях; мы рассмотрим их в пошаговом режиме.

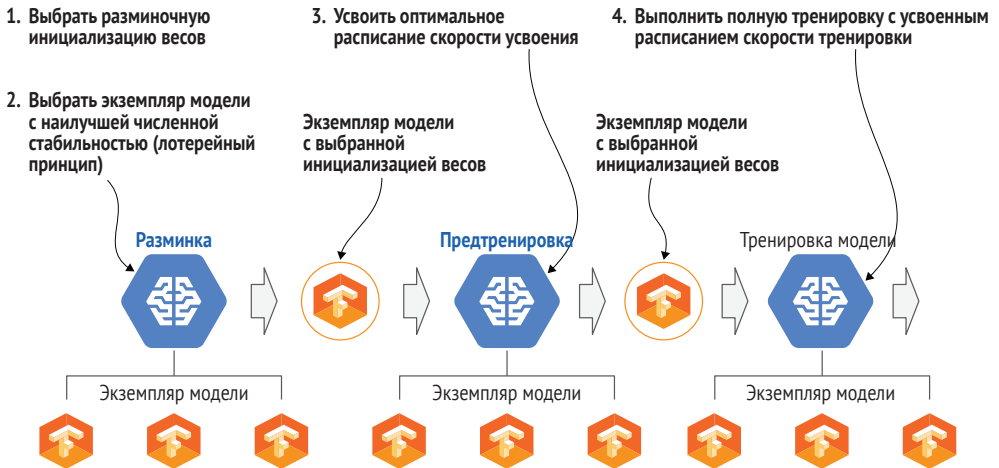


Рис. 10.1 Гиперпараметрический процесс в традиционной производственной среде тренировки

Я кратко пройду по этой диаграмме, чтобы сориентировать вас в процессе, которому мы будем следовать в остальной части этой главы. Первым шагом является выбор для модели наилучшей инициализации весов, и мы потратим некоторое время на понимание того, почему этот выбор может существенно повлиять на исход во время тренировки. Мы начнем с предопределенных распределений, основанных на исследованиях, и перейдем к альтернативному способу взятия выборки из распределения: принципу лотерейного билета.

Затем, с инициализированными весами, мы переходим к разминочной предтренировке. Этот процесс численно стабилизирует веса, что повысит вероятность более оптимального исхода как по времени тренировки, так и по точности модели.

По достижении численной стабильности весов мы обратимся к техническим приемам гиперпараметрического поиска и настройки.

После того как у нас будут хорошо инициализированные и численно стабильные веса и настроенные гиперпараметры, мы переходим к фактической тренировке, начиная с технических приемов дальнейшего повышения возможности более оптимального исхода. Одним из таких приемов, который мы будем использовать здесь, является изменение скорости усвоения на более поздних частях тренировки. Оно может значительно повысить шансы на достижение глобального или близкого к среднему оптимума. Другими словами, эти технические приемы повышают возможность порождения более точных моделей при меньшей совокупной экономической стоимости.

Мы завершим главу описанием широко распространенных практических подходов к регуляризации, которые имплементируются в тренировке во время обновления весов. Регуляризация помогает сокращать запоминание (переподгонку), а также увеличивает обобщение на примеры, которые модель увидит после развертывания в производстве. Мы рассмотрим два технических приема, которые наиболее часто используются в производстве: затухание весов (т. н. *ядерная регуляризация*, или *слоевая регуляризация*) и сглаживание меток.

10.1 Инициализация весов

Когда мы впервые начинаем тренировать модель с нуля, нам нужно придать весам начальное значение. Этот процесс называется *инициализацией*. Для простоты мы могли бы начать с установки всех весов равными одному и тому же значению – скажем, 0 или 1. Однако это не сработает, потому что характер работы градиентного спуска при обратном распространении означает, что каждый вес будет иметь одинаковые обновления.

Нейронная сеть была бы симметричной и эквивалентной лишь одному узлу. Один узел может принимать только одно двоичное решение и может решать лишь задачу с линейным разделением, наподобие логического AND или OR. Решить логическую задачу XOR с помощью одного узла невозможно, так как для этого требуется нелинейное разделение. Неспособность ранней модели персептрона решать задачу XOR приписывается сокращением финансирования и исследований в области искусственного интеллекта с 1984 по 2012 год, которое называют *зимой ИИ*.

Итак, нам нужно установить веса в модели равными случайному распределению значений. В идеале распределение должно иметь малый диапазон (от -1 до 1) и быть центрировано на 0. За последние несколько лет для инициализации весов использовалось несколько диапазонов случайных распределений. Почему веса должны нахо-

даться в пределах малого диапазона значений распределения? Дело в том, что если наш диапазон велик, то более крупные инициализированные веса будут доминировать в обновлении модели над меньшими весами, что приведет к разреженности, меньшей точности и, возможно, отсутствию схождения.

10.1.1 Распределения весов

Давайте начнем с разъяснения разницы между инициализацией весов и распределением весов. *Инициализация весов* – это начальное множество значений весов, отправная точка перед тренировкой модели. *Распределение весов* – это источник, из которого мы отбираем эти начальные веса.

Наиболее популярными среди исследователей оказались три распределения весов. *Равномерное распределение* равномерно распределено по всему диапазону. Оно больше не используется. *Распределение Ксавье*, или *Глоро*, улучшенное по сравнению с равномерным распределением, представляет собой случайное нормальное распределение с центром на нуле. Оно имеет стандартное отклонение, заданное по следующей ниже формуле, где *fan_in* – это число входов в слой:

$\sqrt{1/\text{fan_in}}$.

Указанное распределение было популярным методом в ранних передовых моделях, и оно подходило лучше всего, когда активациями были *tanh* (гиперболический тангенс, или касательная). Сейчас им пользуются редко.

Наконец, у нас есть *Хе-нормальное распределение*, улучшенное по сравнению с распределением Ксавье¹. В наши дни почти вся инициализация весов выполняется с помощью Хе-нормального распределения; это текущее магистральное распределение, и оно лучше всего подходит для активаций *ReLU*. Указанное случайное распределение является нормальным распределением с центром на нуле и стандартным отклонением, установленным по следующей ниже формуле, где *fan_in* – это число входов в слой:

$\sqrt{2/\text{fan_in}}$.

Теперь давайте посмотрим, как это имплементируется. В *TF.Keras* по умолчанию веса инициализируются распределением Ксавье (именуемым *glorot_uniform*). В целях инициализации весов Хе-нормальным распределением необходимо задать именованный параметр

¹ Хе-нормальное (He-Normal) распределение – это усеченное нормальное распределение с центром в 0 и стандартным отклонением, $\text{stddev} = \sqrt{2 / \text{fan_in}}$, где *fan_in* – это число входных единиц в весовом тензоре. – Прим. перев.

`kernel_initializer` в явной форме равным значению `he_normal`. Вот как это выглядит:

```
x = Conv2D(16, (3, 3), strides=1, padding='same', activation='relu',
           kernel_initializer='he_normal')(inputs)
outputs = Dense(10, activation='softmax',
                kernel_initializer='he_normal')(x)
```

← Инициализирует
веса Хе-нормальным
распределением

10.1.2 Лотерейная гипотеза

После того как исследователи пришли к консенсусу относительно распределения, из которого следует черпать веса для инициализации нейронной сети, следующий вопрос состоял в том, каков наилучший метод черпания из распределения. Мы начнем с обсуждения лотерейной гипотезы, положившая начало последовательности быстрых достижений в извлечении выборок из распределения, которая затем привела к концепции численной стабильности (рассмотренной в разделе 10.1.3).

Лотерейная гипотеза для инициализации весов была предложена в 2019 году. Указанная гипотеза выдвигает два предположения:

- никакие две выборки из случайного распределения не являются равными. Некоторые выборки из случайного распределения для инициализации весов производят более оптимальные результаты, чем другие;
- крупные модели обладают высокой точностью, потому что на самом деле они представляют собой набор малых моделей. Каждая из них имеет разные выборки из случайного распределения, и одна из выборок (розыгрыш) является выигрышным билетом.

Последующие попытки идентифицировать и извлечь подмодель с выигрышным билетом в компактную модель из натренированной крупной модели так и не увенчались успехом. В результате метод, предложенный в статье «Гипотеза лотерейного билета» Джонатаном Франклом и Майклом Карбином (The Lottery Ticket Hypothesis, Jonathan Frankle, Michael Carbin, <https://arxiv.org/abs/1803.03635>), сегодня не используется, но последующие исследования привели к другим вариациям. В этом подразделе мы рассмотрим одну из часто используемых вариаций.

Однако вопрос о «выигрышном билете» еще не урегулирован. Еще один лагерь практиков машинного обучения использует методологию предтренировки многочисленных экземпляров модели, каждый с отдельной выборкой. В типичной ситуации при использовании этого подхода мы выполняем небольшое число эпох с очень малой скоростью усвоения (например, 0.0001). Для каждой эпохи число шагов существенно меньше, чем размер тренировочных данных. Поступая таким образом, мы можем преднатренировать крупное число эк-

земпляров за короткий промежуток времени. После завершения выбирается экземпляр модели с наилучшей целевой метрикой, такой как тренировочная потеря. При этом исходят из допущения, что эта выборка является более оптимальным выигрышным билетом, чем другие.

Рисунок 10.2 иллюстрирует предтренировку экземпляров модели с использованием метода лотерейной гипотезы. Для тренировки создается несколько экземпляров опорной модельной архитектуры, каждая с разной выборкой из случайного распределения. Затем каждый экземпляр предтренируется с одинаковой скоростью усвоения в течение малого числа эпох / сокращенных шагов. Если вычислительные ресурсы доступны, то предтренировка распределяется. После завершения проверяется тренировочная потеря каждой преднатренированной модели. Экземпляр с наименьшей тренировочной потерей является экземпляром с наилучшей выборкой – выигрышным билетом.

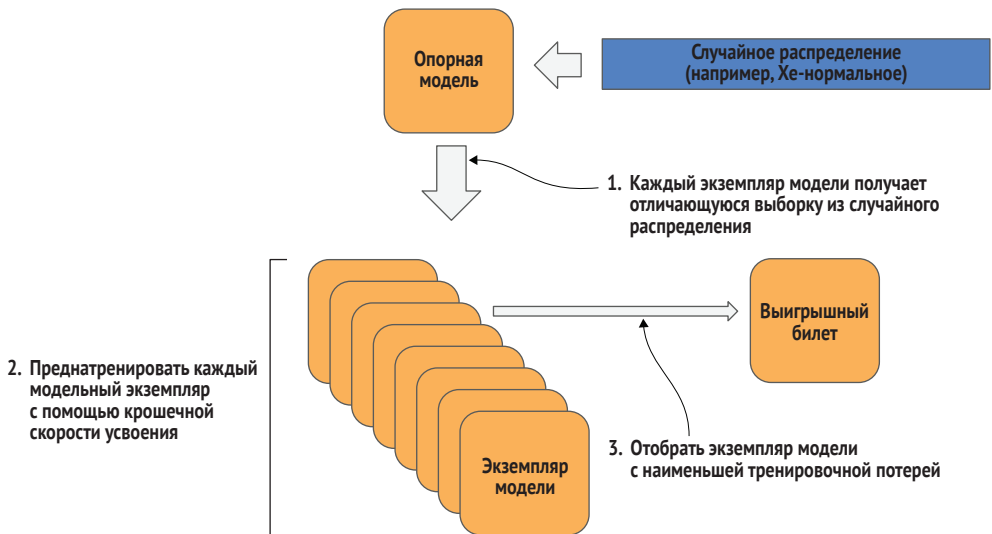


Рис. 10.2 Предтренировка с использованием метода лотерейной гипотезы

Этот процесс можно имплементировать с помощью следующего ниже исходного кода. Главенствующие шаги, показанные в данном примере, таковы.

- 1 Создать 10 экземпляров модели, каждый с отдельной выборкой для инициализации весов. Мы делаем это, чтобы эмулировать принцип, согласно которому нет двух одинаковых выборок. Выбор 10 экземпляров является совершенно произвольным и служит для данного примера. Чем больше число экземпляров, каждый с отдельной выборкой, тем больше вероятность того, что одна из этих выборок окажется выигрышным билетом.

- 2 Натренировать каждый экземпляр в течение малого числа эпох и шагов.
- 3 Отобрать экземпляр модели (best) с наименьшей тренировочной потерей.

Соответствующий исходный код приведен ниже:

```
def make_model():
    ''' Создать экземпляр модели '''
    bottom = ResNet50(include_top=False, weights=None,
                      input_shape=(32, 32, 3))
    model = Sequential()
    model.add(bottom)
    model.add(Flatten())
    model.add(Dense(10, activation='softmax'))
    model.compile(loss='sparse_categorical_crossentropy',
                  optimizer=Adam(0.0001),
                  metrics=['acc'])

    return model

lottery = []
for _ in range(10):
    lottery.append(make_model())

from tensorflow.keras.datasets import cifar10
from tensorflow.keras.preprocessing.image import ImageDataGenerator
import numpy as np

(x_train, y_train), (x_test, y_test) = cifar10.load_data()
x_train = (x_train / 255.0).astype(np.float32)

best = (None, 99999)
datagen = ImageDataGenerator()
for model in lottery:
    result = model.fit(datagen.flow(x_train, y_train, batch_size=32),
                      epochs=3,
                      steps_per_epoch=100)
    print(result.history['loss'][2])
    loss = result.history['loss'][2]
    if loss < best[1]:
        best = (model, loss)
```

Создает 10 экземпляров модели, каждый с отдельной выборкой для инициализации

Выполняет предтренировку и отбирает экземпляр с наименьшей тренировочной потерей

Далее мы рассмотрим еще один подход к инициализации весов, используя разминку для численной стабилизации весов.

10.1.3 Разминка (численная стабилизация)

Метод численной стабилизации, в котором для инициализации весов используется подход, отличный от лотерейной гипотезы, в настоящее время является преобладающим методом инициализации весов перед полной тренировкой. В лотерейной гипотезе крупная модель рассматривается как набор подмоделей, и у одной подмодели есть

выигрышный билет. В методе численной стабилизации крупная модель делится на верхние (вершину) и нижние (дно) слои.

Хотя ранее мы обсуждали деление на *дно* и *вершину*, некоторым читателям эта терминология все еще может показаться отсталой – для меня это точно так. В нейронной сети входной слой является дном, а выходной слой – вершиной. Входные данные поступают из дна модели, а предсказания выводятся на вершине.

Предполагается, что нижние слои (дно) обеспечивают численную стабильность более высоких слоев (вершины) во время тренировки. Или, конкретнее, нижние слои обеспечивают численную стабильность для более высоких слоев, чтобы *узнать* выигрышный билет (инициализационную выборку). Этот процесс показан на рис. 10.3.

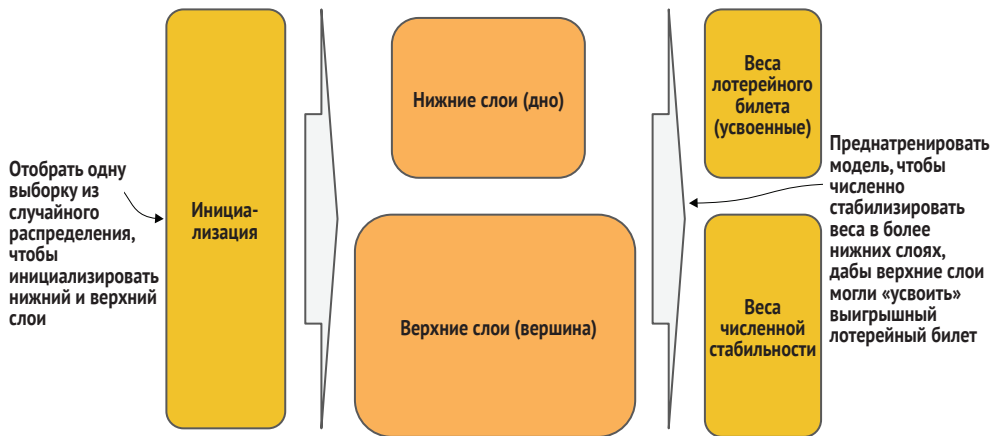


Рис. 10.3 Предтренировка для численной стабилизации нижних слоев, чтобы более высокие слои усвоили инициализацию выигрышного лотерейного билета

Этот метод обычно имплементируется как разминочный цикл тренировки перед полной тренировкой модели. В разминочной тренировке мы начинаем с очень низкой скорости усвоения, чтобы избежать крупных колебаний весов и заставить веса сдвигаться в сторону выигрышного билета. Типичные начальные значения разминочной скорости усвоения находятся в диапазоне от $1e-5$ до $1e-4$.

Мы тренируем модель в течение малого числа эпох, обычно четырех или пяти, и постепенно повышаем скорость усвоения после каждой эпохи до начальной скорости усвоения, выбранной для тренировки.

Рисунок 10.4 иллюстрирует метод разминочной тренировки, изображенный ранее в виде шагов 1, 2 и 3 на рис. 10.1. В отличие от лотерейной гипотезы, мы начинаем с тренировки одного экземпляра опорной модели. Начиная с очень низкой скорости усвоения, при которой веса корректируются на крошечные величины, модель тренируется с использованием полных эпох. Всякий раз скорость усвоения является поступательно пропорциональной начальной скорости

усвоения в полной тренировке. По достижении последней эпохи веса в экземпляре модели считаются численно стабильными.

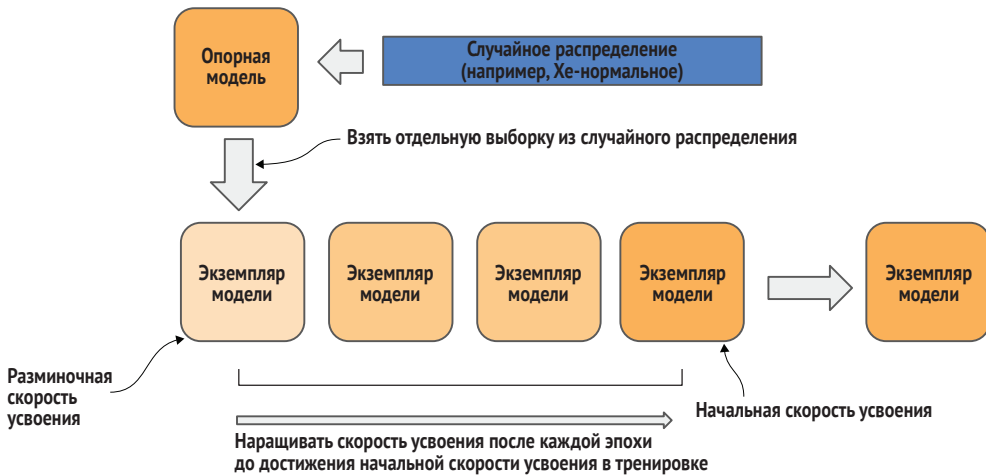


Рис. 10.4 Разминочная предтренировка для численной стабилизации

В следующем ниже примере исходного кода можно увидеть имплементацию четырех ключевых шагов:

- 1 инстанцировать одну модель с инициализированными весами;
- 2 определить планировщик скорости усвоения `warmup_scheduler()` для наращивания скорости усвоения после каждой эпохи. В разделе 10.3 планировщики скорости усвоения описываются подробно;
- 3 добавить разминочный планировщик в качестве обратного вызова для метода `fit()`;
- 4 тренировать в течение малого числа эпох (например, четырех).

```
def make_model(w_lr):
    ''' Создать экземпляр модели '''
    bottom = ResNet50(include_top=False, weights=None,
                      input_shape=(32, 32, 3))
    model = Sequential()
    model.add(bottom)
    model.add(Flatten())
    model.add(Dense(10, activation='softmax'))
    model.compile(loss='sparse_categorical_crossentropy',
                  optimizer=Adam(w_lr),
                  metrics=['acc'])

    return model

w_lr = 0.0001
i_lr = 0.001
w_epochs = 4
w_step = (i_lr - w_lr) / w_epochs
```

Задаёт разминочную скорость усвоения и шаг скорости усвоения

```

model = make_model(w_lr)
def warmup_scheduler(epoch, lr):
    """ Планировщик скорости усвоения для разминочной тренировки
        epoch : текущая итерация в эпохах
        lr : текущая скорость усвоения
    """
    if epoch == 0:
        return lr
    return lr + w_step

from tensorflow.keras.callbacks import LearningRateScheduler
lrate = LearningRateScheduler(warmup_scheduler, verbose=1)
from tensorflow.keras.datasets import cifar10
from tensorflow.keras.preprocessing.image import ImageDataGenerator
import numpy as np

(x_train, y_train), (x_test, y_test) = cifar10.load_data()
x_train = (x_train / 255.0).astype(np.float32)
result = model.fit(x_train, y_train, batch_size=32, epochs=4,
                   validation_split=0.1,
                   verbose=1, callbacks=[lrate])

```

Создает модель и устанавливает начальную скорость усвоения равной разминочной скорости

Поступательно увеличивается с разминочной скорости до начальной скорости усвоения, используемой в полной тренировке

Создает обратный вызов планировщика скорости усвоения

Теперь, когда мы рассмотрели предтренировку, давайте взглянем на фундамент, положенный в основу гиперпараметрического поиска. Затем мы применим все, чему вы здесь научились, на практике и проведем полную тренировку модели.

10.2 Основы гиперпараметрического поиска

Как только инициализация весов вашей модели достигнет числовой стабильности (будь то лотерея или разминка), мы выполняем *гиперпараметрический поиск*, т. н. *гиперпараметрическую настройку*, или *гиперпараметрическую оптимизацию*.

Вспомните, что цель гиперпараметрического поиска – отыскать (почти) оптимальную гиперпараметрическую настройку, чтобы максимизировать тренировку вашей модели с целью достижения вашего целевого критерия, которым может быть, например, скорость усвоения или оценочная точность. И как мы также обсуждали, мы проводим различие между параметрами конфигурации модели, именуемыми *метапараметрами*, и параметрами тренировки, именуемыми *гиперпараметрами*. В этом разделе мы сосредоточимся только на гиперпараметрической настройке.

В типичной ситуации во время тренировки предварительно сконфигурированной модели единственными гиперпараметрами, которые мы пытаемся отрегулировать, являются следующие:

- скорость усвоения;
- размер пакета;

- планировщик скорости усвоения;
- регуляризация.

ПРИМЕЧАНИЕ Не выполняйте гиперпараметрический поиск на модели, веса которой не были численно стабилизированы. Без численной стабилизации весов практикующий специалист может непреднамеренно отбросить комбинации со слабой результативностью, которые во всем остальном могут оказаться хорошей комбинацией.

Давайте начнем с визуального представления. На рис. 10.5 показано пространство поиска. Черная область представляет гиперпараметрические комбинации, которые дают оптимальные результаты. В пространстве поиска могут существовать многочисленные области оптимальных комбинаций; в данном случае у нас три черные точки. В типичной ситуации в пределах окрестности каждой оптимальной области находится более крупная область почти оптимальных результатов, представленная серым цветом. Представленная пробелами подавляющая часть пространства поиска дает неоптимальные (и не близкие к оптимуму) результаты.




Рис. 10.5 Пространство гиперпараметрического поиска

По преобладанию белого пространства над черным можно судить, что если бы вы выбрали случайную горстку комбинаций гиперпараметров, то вероятность отыскать оптимальный или почти оптимальный результат была бы крайне малой. Итак, вам нужна стратегия. Хорошая стратегия – это стратегия, которая имеет высокую вероятность приземлиться в районе (районах), близком к оптимальному; расположение в пределах области, близкой к оптимальной, сужает пространство поиска отысканием оптимальной области в пределах окрестности.

10.2.1 Ручной метод гиперпараметрического поиска

Давайте начнем с того, что пройдемся по ручному методу, а потом перейдем к автоматизированному поиску. У меня большой опыт тренировки моделей компьютерного зрения, и я обладаю сильной интуицией в том, что касается отбора гиперпараметров. Я могу использовать эту приобретенную интуицию, чтобы выполнять поиск в ручном режиме. Обычно я придерживаюсь следующих ниже четырех начальных шагов:

- 1 выполнить грубую настройку начальной скорости усвоения;
- 2 настроить уровень пакета;
- 3 выполнить тонкую настройку начальной скорости усвоения;
- 4 настроить планировщик скорости усвоения.

ГРУБАЯ НАСТРОЙКА НАЧАЛЬНОЙ СКОРОСТИ УСВОЕНИЯ

Я начинаю с использования фиксированного размера пакета и фиксированной скорости усвоения. Если это малый набор данных, обычно 50 000 примеров или меньше, то я использую пакет размером 32 элемента; в противном случае использую пакет размером 256 элементов. Я выбираю центральную точку скорости усвоения – обычно 0.001. Затем провожу эксперименты в центральной точке (например, 0.001) и на один порядок величины больше (например, 0.01) и меньше (0.0001). Я смотрю на валидационную потерю и точность между тремя прогонами и решаю, какое направление ведет к более оптимальному схождению.

Если у меня будет прогон с наименьшей валидационной потерей и наивысшей валидационной точностью, то я выберу этот вариант. Иногда меньшая валидационная потеря на одном прогоне не приводит к более высокой точности. В этих случаях я больше руководствуюсь интуицией, но склоняюсь к принятию решения о наименьшей валидационной потере.

Затем я выбираю новую центральную точку на полпути между существующей и более оптимальной точками схождения. Например, если центральная точка и точка схождения равны 0.001 и 0.01, то я выбираю 0.005 в качестве центра и использую на один порядок величины больше (0.05) и меньше (0.0005) и повторяю эксперимент. Я повторяю эту стратегию «разделяй и властвуй» до тех пор, пока центральная точка не даст мне наилучшее схождение, которое становится грубо настроенной начальной скоростью усвоения. Существует высокая вероятность того, что я нахожусь почти в оптимальной (серой) области.

НАСТРОЙКА УРОВНЯ ПАКЕТА

Затем я настраиваю размер пакета. В целом использование 32 элементов для малых и 256 для крупных наборов данных представляет

самые низкие уровни. Поэтому я пробую более высокие. Использую коэффициент $2\times$. Например, если размер моего пакета 32, то я пробую 64 с максимальной скоростью усвоения. Если схождение улучшается, то затем пробую 128 и т. д. Когда оно не улучшается, то я выбираю предыдущее хорошее значение.

Тонкая настройка начальной скорости усвоения

На данный момент существует высокая вероятность того, что я приблизился к оптимальной (черной) области. Чем больше размер пакета, тем меньше будет дисперсия в потере в расчете на партию. Как следствие обычно можно повысить скорость усвоения, если был увеличен размер пакета.

Учитывая более крупный размер партии, я повторяю эксперименты по настройке скорости усвоения, используя грубую скорость усвоения в качестве начальной центральной точки.

План скорости усвоения

В этом месте я начинаю полный прогон тренировки с ранней остановкой, когда валидационная точность перестает улучшаться. Обычно сначала я пробую косинусное закаливание на скорости усвоения (обсуждается впоследствии). Если это приводит к значительному улучшению, то я чаще всего останавливаюсь на достигнутом. В противном случае я оглядываюсь назад на начальный полный прогон и нахожу эпоху, когда валидационная точность снизилась или разошлась. Затем определяю планировщик скорости усвоения, чтобы снизить скорость усвоения на один порядок величины за одну эпоху до этой точки.

Как правило, это дает мне действительно хорошую отправную точку, и теперь я могу сосредоточиться на других шагах предтренировки, таких как обогащение и сглаживание меток (обсуждается в разделе 10.4).

10.2.2 Решеточный поиск

Решеточный поиск – это старейшая форма гиперпараметрического поиска. Он означает, что вы ищете все возможные комбинации в узком пространстве поиска; это врожденный человеческий подход к новой задаче в целях получения представления. Он практичен только при наличии нескольких параметров и значений. Например, если у нас три значения скорости усвоения и два размера пакета, то число комбинаций будет 3×2 , или 6, что выполнимо на практике. Давайте лишь слегка увеличим это значение до пяти значений скорости усвоения и трех размеров пакета. Теперь это 5×3 , или 15. Блеск! Вы только посмотрите на быстроту, с которой растут комбинации!

Поскольку (почти) оптимальная область намного меньше по сравнению со всем поиском, мы вряд ли найдем хорошую комбинацию на ранней стадии.

Указанный подход больше не используется из-за его вычислительных издержек. Ниже приведен пример имплементации решеточного поиска. Я представляю его здесь, чтобы вы могли провести сравнение со случайным поиском в следующем подразделе.

В данном примере мы выполняем решеточный поиск на двух гиперпараметрах: скорости усвоения (*lr*) и размере пакета (*bs*). Для обоих мы указываем набор значений, которые нужно попробовать, например `[0.1, 0.01]` для скорости усвоения. Затем мы используем два вложенных циклических итератора, чтобы сгенерировать все комбинации набора значений скорости усвоения и размера пакета. По каждой комбинации мы получаем копию преднатренированного экземпляра модели (`get_model()`) и тренируем ее в течение нескольких эпох. При этом ведется скользящий итог наилучшего валидационного балла и соответствующей комбинации гиперпараметров (*best*). По завершении кортеж *best* содержит значения гиперпараметров, которые привели к наименьшей валидационной потере.

```
best = (None, 0, 0, 0)
epochs = 5

for lr in [0.1, 0.01]:
    for bs in [32, 64]:
        model = get_model(lr)

        result = model.fit(x_train, y_train, batch_size=bs, epochs=epochs,
                           validation_split=0.1)

        val_acc = result.history['val_acc'][epochs-1]
        if val_acc > best[1]:
            best = (model, val_acc, lr, bs)
```

Решеточный поиск для трех скоростей усвоения и двух размеров пакета

Задаёт скорость усвоения при компилировании модели

Тренирует в течение нескольких эпох

Использует валидационную точность, чтобы отобрать наилучшую комбинацию скорости усвоения и размера пакета

10.2.3 Случайный поиск

Теперь давайте обратимся к методу случайного поиска, который является менее вычислительно дорогостоящим, чем решеточный поиск для отыскания хороших гиперпараметров. Ваш первый вопрос может заключаться в следующем: как случайный поиск может быть вычислительно менее дорогостоящим, чем решеточный поиск (он же просто случайный)?

В целях ответа на этот вопрос вернемся к предыдущему описанию пространства гиперпараметрического поиска. Мы знаем, что лишь малая его часть имеет оптимальную комбинацию, поэтому у нас очень низкая вероятность найти ее случайно. Но мы также знаем, что существенно более крупные области близки к оптимальным, поэтому при использовании случайного поиска у нас значительно выше вероятность приземлиться в одной из них.

Как только поиск находит почти оптимальную комбинацию, мы знаем, что существует хорошая возможность, что в окрестности су-

ществует оптимальная комбинация. В этом месте мы сужаем случайный поиск до области, окружающей почти оптимальную комбинацию. Если новая комбинация улучшит результат, то можно еще больше сузить область случайного поиска вокруг новой комбинации.

Подведем итог этим шагам.

- 1 Установить границы пространства поиска.
- 2 Выполнить случайный поиск по всему пространству поиска.
- 3 Как только будет найдена почти оптимальная комбинация, сузить область поиска до области, близкой к новой комбинации.
- 4 Непрерывно повторять до тех пор, пока комбинация не будет соответствовать вашим целевым критериям.
 - Если новая комбинация улучшает результат, то еще больше сузить пространство поиска вокруг новой комбинации.
 - Если после определенного числа испытаний результат не улучшится, то вернуться к поиску по всему пространству поиска (шаг 2).

Рисунок 10.6 иллюстрирует первые три шага.




Рис. 10.6 Гиперпараметрический случайный поиск

Ниже приведен пример имплементации первых трех шагов. В данном исходном коде делается следующее.

- 1 Выполнить пять пробных испытаний (trials) на всем пространстве поиска. Поскольку в этом примере содержится лишь малое число комбинаций, обычно достаточно пяти испытаний.
- 2 Отобрать случайную комбинацию скорости усвоения (lr) и размера пакета (bs).
- 3 Выполнить короткий прогон тренировки на преднатренированном экземпляре модели.
- 4 Вести скользящий итог наилучшей валидационной точности и комбинации гиперпараметров (best).

- 5 Отобрать наилучшую валидационную точность из пяти испытаний как почти оптимальную.
- 6 Установить узкое пространство поиска вокруг почти оптимальных гиперпараметров ($2X$ и $1/2X$).
- 7 Выполнить еще пять испытаний в узком пространстве поиска.

```

from random import randint

learning_rates = [0.1, 0.01, 0.001, 0.0001]
batch_sizes = [32, 128, 512]

trials = 5
epochs = 3

best = (None, 0, 0, 0)

for _ in range(trials):
    lr = learning_rates[randint(0, 3)]
    bs = batch_sizes[randint(0, 2)]
    model = get_model(lr)
    result = model.fit(x_train, y_train, epochs=epochs, batch_size=bs,
                      validation_split=0.1, verbose=0)
    val_acc = result.history['val_acc'][epochs-1]
    if val_acc > best[1]:
        best = (model, val_acc, lr, bs)

learning_rates = [best[2] / 2, best[2] * 2]
batch_sizes = [best[3] // 2, int(best[3] * 2)]
for _ in range(trials):
    lr = learning_rates[randint(0, 1)]
    bs = batch_sizes[randint(0, 1)]
    model = get_model(lr)
    result = model.fit(x_train, y_train, epochs=epochs, batch_size=bs,
                      validation_split=0.1, verbose=0)

    val_acc = result.history['val_acc'][epochs-1]
    if val_acc > best[1]:
        best = (model, val_acc, lr, bs)

```

Шаг 1: первый раунд испытаний, находит наилучшую, почти оптимальную комбинацию

Шаг 2: отбирает случайную комбинацию

Шаг 3: выполняет короткий прогон тренировки для испытания

Шаги 4 и 5: вести итог текущих наилучших результатов

Шаг 6: сужает пространство поиска до окрестности наилучшего, почти оптимального

Шаг 7: выполняет еще один набор испытаний вокруг суженного пространства поиска

Если бы мы провели решеточный поиск, то у нас было бы $4 \times 3 = 12$ комбинаций

Я выполнил этот исходный код без численной стабилизации, используя набор данных CIFAR-10. После первых пяти испытаний в полном пространстве поиска наилучшая валидационная точность составила 0.352. После сужения пространства поиска наилучшая валидационная точность возросла до 0.487, при скорости усвоения = 0.0002 и размере пакета = 64.

Затем я повторил процесс, но на этот раз, прежде чем выполнять гиперпараметрический поиск, сначала выполнил численную стабилизацию модели. Я обновил метод `get_model()`, чтобы получить копию сохраненной численно стабилизированной модели. После первых пяти испытаний в полном пространстве поиска наилучшая валидационная точность составила 0.569. После сужения простран-

ства поиска наилучшая валидационная точность возросла до 0.576 при скорости усвоения = 0.1 и размере пакета = 512. Блеск! Это удивительно лучше. И мы еще не проводили регулировку плана скорости усвоения, регуляризацию, обогащение и сглаживание меток!

Далее мы обсудим вопрос использования автоматизированного инструмента гиперпараметрического поиска KerasTuner, который представляет собой прилагаемый к TF.Keras модуль. Вы, возможно, спросите: зачем изучать ручной метод, когда можно просто использовать автоматизированный метод? Ориентироваться в пространстве поиска необходимо даже при использовании автоматизированного метода. Применение ручных методов поможет вам приобрести опыт в управлении пространством поиска. Для меня и исследователей разработка ручных методов дает представление о будущих улучшениях автоматизированного поиска. Наконец, вы можете обнаружить, что автоматизированный метод «прямо из коробки» плохо подходит к вашему собственному набору данных и модели, и вы сможете его улучшить с помощью своего уникального приобретенного подхода.

10.2.4 Инструмент настройки KerasTuner

KerasTuner – это прилагаемый к TF.Keras модуль для автоматизированной гиперпараметрической настройки. Он имеет два метода: случайный поиск и поиск методом hyperband. Для краткости в этом разделе рассматривается метод случайного поиска. Понимание этого метода даст вам представление об общем подходе к гиперпараметрическому поиску в том, что в противном случае является разреженным пространством, когда в более широком пространстве поиска существует несколько хороших комбинаций.

ПРИМЕЧАНИЕ Я отсылаю вас к онлайн-официальной документации (<https://keras-team.github.io/keras-tuner/>) по hyperband, подходу на основе бандитского алгоритма для улучшения времени случайного поиска. Более подробную информацию о нем можно найти в статье «Hyperband» Лиши Ли и соавт. (Lisha Li et al., <https://arxiv.org/abs/1603.06560>)¹.

Как и у всех автоматизированных инструментов, у KerasTuner есть свои плюсы и минусы. Быть автоматизированным и довольно простым в использовании, очевидно, хорошо. Для меня отсутствие возможности настраивать размер пакета является большим недостатком, так как в итоге вам придется настраивать размер пакета вручную.

Вот команда pip для инсталлирования KerasTuner:

```
pip install -U keras-tuner
```

¹ В названии метода hyperband авторы совместили два термина: гиперпараметрическая оптимизация и бандитский алгоритм. – Прим. перев.

Для того чтобы использовать KerasTuner, мы начнем с создания экземпляра настройщика. В следующем ниже примере создаем экземпляр библиотечного класса RandomSearch. Этот экземпляр принимает три необходимых параметра:

- 1 гиперпараметрически настраиваемая модель (hp);
- 2 целевая мера (например, валидационная точность);
- 3 максимальное число тренировочных испытаний (экспериментов).

```
from kerastuner.tuners import RandomSearch
tuner = RandomSearch(
    hp_model,
    objective='val_acc',
    max_trials=3)

```

Получает гиперпараметрически настраиваемую модель

Тренировочная метрика для сравнения (улучшений)

Число тренировочных испытаний → max_trials=3)

В данном примере я установил минимальное число испытаний (3) для демонстрационных целей. Будет опробовано не более трех случайных комбинаций. В зависимости от размера вашего пространства поиска, как правило, вы будете использовать большее число. Это компромисс. Чем больше испытаний, тем больше разведывается пространство поиска, но тем больше требуется вычислительных затрат (времени).

Затем мы создаем функцию, которая инстанцирует гиперпараметрически настраиваемую модель. Указанная функция принимает один параметр, hp. Это гиперпараметрическая контрольная переменная, передаваемая в KerasTuner.

В нашем примере мы настроим только скорость усвоения. Мы начнем с получения экземпляра численно стабилизированной версии нашей модели, как я рекомендовал ранее. Затем устанавливаем скорость усвоения для этого экземпляра с помощью параметра optimizer в методе compile(). В нашем примере мы зададим четыре варианта скорости усвоения с помощью метода hp.Choice() гиперпараметрического настройщика (hp). Он указывает настройщику набор значений параметра, среди которых следует искать. В данном случае мы задаем варианты значений [1e-1, 1e-2, 1e-3, 1e-4]:

```
def hp_model(hp):
    ''' hp передается настройщиком '''
    model = tf.keras.models.load_model('numeric')
    model.compile(
        loss='sparse_categorical_crossentropy', metrics=['acc'],
        optimizer=Adam(hp.Choice('learning_rate',
                                  values=[1e-1, 1e-2, 1e-3, 1e-4])))
    return model

```

Загружает сохраненную (на диске) модель

Перекомпилирует модель для сброса скорости усвоения

Делает скорость усвоения настраиваемым параметром

Далее мы готовы выполнить гиперпараметрическую настройку. Мы иницилируем поиск с помощью метода search() настройщика (tuner). Указанный метод принимает те же параметры, что и метод

`fit()` модели Keras. Обратите внимание, что размер пакета указан в функции `search()` в явной форме и, следовательно, не настраивается автоматически. В нашем примере тренировочными данными являются тренировочные данные CIFAR-10:

```
tuner.search(x_train, y_train, batch_size=32, validation_data=(x_test, y_test))
```

А теперь результаты! Во-первых, давайте применим метод `results_summary()`, чтобы просмотреть сводку испытаний:

```
tuner.results_summary()
```

Вот результат, который показывает, что наилучшей скоростью усвоения было значение 0.1:

```
Results summary
|-Results in ./untitled_project
|-Showing 10 best trials
|-Objective(name='val_acc', direction='max')
Trial summary
|-Trial ID: 0963640822565bfc03280657d5350d26
|-Score: 0.4927000105381012
|-Best step: 0
Hyperparameters:
|-learning_rate: 0.0001
Trial summary
|-Trial ID: 9c6ed7a1276c55a921eaf1d3f528d64d
|-Score: 0.28610000014305115
|-Best step: 0
Hyperparameters:
|-learning_rate: 0.01
Trial summary
|-Trial ID: d269858c936c2b6a2941e66f880304c7
|-Score: 0.10599999874830246
|-Best step: 0
Hyperparameters:
|-learning_rate: 0.1 ← Отобранная наилучшая скорость усвоения
```

Затем вы применяете метод `get_best_models()`, чтобы получить соответствующую модель. Этот метод возвращает список наилучших моделей в порядке убывания на основе параметра `num_models`. В данном случае нам нужен только самый лучший вариант, поэтому мы устанавливаем его равным 1.

```
models = tuner.get_best_models(num_models=1)
model = models[0]
```

Наконец, ваши результаты и модели хранятся в папке, которую можно указать с помощью параметра `project_name` при создании экземпляра настройщика. Если не указано иное, по умолчанию имя папки равно `untitled_project`. В целях проведения очистки после ваших испытаний необходимо эту папку удалить.

10.3 Планировщик скорости усвоения

Ранее в наших примерах мы держали скорость усвоения постоянной на протяжении всей тренировки. При постоянной скорости усвоения можно получать хорошие результаты, но это не так эффективно, как регулировка скорости усвоения во время тренировки.

В типичной ситуации во время тренировки вы переходите от более высокой скорости усвоения к более низкой. Изначально вы хотите начать с максимально высокой скорости усвоения, не вызывая численной нестабильности. Более крупная скорость усвоения позволяет оптимизатору разведывать разные пути (локальные оптимумы) к схождению и добиваться некоторых первоначальных значительных успехов в минимизации потери, чтобы ускорять тренировку.

Но если сразу после того, как мы добьемся значительного прогресса в достижении хорошего локального оптимума, мы продолжим использовать высокую скорость усвоения, то можем начать осциллировать взад-вперед, не достигая схождения, либо непреднамеренно выскочить из хорошего локального оптимума и начать сходиться в менее хорошем локальном оптимуме.

Поэтому по мере приближения к схождению мы начинаем снижать скорость усвоения, делая шаги все меньше и меньше, чтобы не осциллировать и отыскать наилучший путь в локальном оптимуме, на котором мы хотим сходиться.

Итак, что подразумевается под термином «планировщик скорости усвоения»? Он означает, что у нас будет метод, который отслеживает процесс тренировки и на основе определенного условия вносит изменения в скорость усвоения, чтобы отыскать и приблизиться к наилучшему или близкому локальному оптимуму. В данном разделе мы рассмотрим несколько распространенных методов, в том числе затухание во времени, рампу, постоянный шаг и косинусное закаливание. Мы начнем с описания метода затухания во времени, то есть метода, встроенного в набор оптимизаторов TF.Keras для постепенного снижения скорости усвоения во время тренировки.

10.3.1 Параметр затухания в Keras

Оптимизаторы TF.Keras поддерживают поступательное снижение скорости усвоения с помощью параметра затухания, `decay`. Оптимизаторы используют метод затухания во времени. Математическая формула для затухания во времени выглядит следующим образом, где lr – это скорость усвоения, k – затухание, а t – число итераций (например, эпох):

$$lr = lr0 / (1 + kt).$$

В TF.Keras затухание во времени имплементировано следующим образом:

$lr = lr \times (1.0 / (1.0 + \text{затухание} \times \text{итерации}))$.

Вот пример установки затухания во времени для скорости усвоения при указании оптимизатора в методе `compile()`:

```
model.compile(optimizer=SGD(lr=0.1, decay=1e-3))
```

В табл. 10.1 показана прогрессия скорости усвоения в течение 10 эпох с приведенными выше настройками; типичные значения затухания находятся в диапазоне от $1e-3$ до $1e-6$.

Таблица 10.1. Динамика затухания скорости усвоения по эпохам

Итерация (эпоха)	Скорость усвоения
1	0.0999
2	0.0997
3	0.0994
4	0.0990
5	0.0985
6	0.0979
7	0.0972
8	0.0964
9	0.0955
10	0.0945

10.3.2 Планировщик скорости усвоения в Keras

Если использование затухания во времени не дает оптимальных результатов, то можно имплементировать свой собственный конкретно-прикладной метод поступательного снижения скорости усвоения, используя обратный вызов `LearningRateScheduler`. В производственной среде нередко коллектив машинного обучения со временем экспериментирует и отыскивает конкретно-прикладные фишки, которые делают тренировку эффективнее по времени и приводят к более качественным исходам в достижении целевого критерия, такого как точность классификации после развертывания в производстве.

Следующий ниже исходный код является примером имплементации, шаги которой описаны здесь.

- 1 Определить функцию обратного вызова планировщика скорости усвоения.
- 2 Во время тренировки (с помощью метода `fit()`) параметрами, передаваемыми обратному вызову, являются текущее число эпох (`epoch`) и скорость усвоения (`lr`).
- 3 В первой эпохе вернуть текущее (начальное) значение скорости усвоения.

- 4 В противном случае постепенно снижать скорость усвоения.
- 5 Инстанцировать обратный вызов планировщика скорости усвоения.
- 6 Передать обратный вызов методу `fit()`.

```
from tensorflow.keras.callbacks import LearningRateScheduler
```

```
def lr_scheduler(epoch, lr):
```

```
    ''' Установить скорость усвоения в начале эпохи
```

```
    epoch: число эпох (первая эпоха равна нулю)
```

```
    lr: текущая скорость усвоения
```

```
    ...
```

```
    if epoch == 0:
```

```
        return lr
```

```
    return n_lr
```

Шаг 1:
устанавливает
начальную
скорость
усвоения

Шаг 3: в первой (0) эпохе начинает
с начальной скорости усвоения

Шаг 4: добавить свою имплементацию
для поступательного снижения скорости усвоения

```
model.compile(loss='categorical_crossentropy', optimizer=Adam(lr=0.01))
```

```
lr_callback = LearningRateScheduler(lr_scheduler)
```

```
model.fit(x_train, y_train, epochs=epochs, batch_size=batch_size,  
        callbacks=[lr_callback])
```

Шаг 5: создает обратный вызов
планировщика скорости усвоения

Шаги 2 и 6: активирует планировщика
скорости усвоения для тренировки

10.3.3 Рампа

Итак, вы выполнили шаг предтренировки с целью численной стабилизации и гиперпараметрическую настройку размера пакета и начальной скорости усвоения. Теперь вы готовы приступить к имплементации вашего алгоритма планировщика скорости усвоения. Нередко это можно сделать с помощью *алгоритма рампового ската*, который сбрасывает скорость усвоения через определенное число эпох. Как правило, в этом месте я провожу длительный прогон тренировки. Обычно начинаю с 50 эпох и устанавливаю условие ранней остановки при валидационной потере (с параметром `patience 2`). Независимо от набора данных, я склонен видеть одну из двух вещей:

- устойчивое и неуклонное сокращение валидационной потери на протяжении последних (50) эпох;
- перед последней эпохой валидационная потеря выходит на плато, и запускается ранняя остановка.

Если я увижу устойчивое сокращение валидационной потери, то буду продолжать повторять еще в течение 50 эпох, пока не сделаю раннюю остановку.

Как только я делаю раннюю остановку, я смотрю, в какую эпоху это произошло. Допустим, это было в эпоху 40. Затем я вычитаю несколько эпох, обычно 5 (в данном случае получается 35). Потом подключаю свой планировщик скорости усвоения, чтобы тот снижал скорость ус-

воения на один порядок величины в эпоху. Почти в 100 % случаев тренировка улучшается, достигая более низкой валидационной потери и более высокой валидационной точности. На рис. 10.7 показана рамповая скорость усвоения.



Рис. 10.7 Рамповое падение скорости усвоения

Ниже приведен пример имплементации планировщика рампового падения скорости усвоения:

`epoch_ramp = 35` ← Задает эпоху для рампового падения на один порядок величины

```
def lr_scheduler(epoch, lr):
    if epoch == epoch_ramp:
        return lr / 10.0
    return lr
```

Снижает скорость усвоения на один порядок величины, когда она находится в эпохе ramпы

Обычно это не последний мой шаг, но вместо этого я использую его, чтобы получить представление о том, как мог бы выглядеть ландшафт потери для этого набора данных. Исходя из этого, я планирую свой полный планировщик скорости усвоения. На этом уровне было бы слишком сложно объяснить ландшафт потери. Вместо этого я расскажу о различных стратегиях планирования скорости усвоения, которые вы можете попробовать.

10.3.4 Постоянный шаг

В методе *постоянного шага* мы хотим перейти от начальной скорости усвоения к нулю в последней эпохе четными шагами. Метод прост. Берется начальная скорость усвоения и делится на число эпох. Рисунок 10.8 иллюстрирует этот метод.

Ниже приведен пример имплементации пошагового метода для планировщика скорости усвоения:

```
epochs = 200  ← Число эпох в тренировке
lr = 0.001    ← Начальная скорость усвоения определяется гиперпараметрической настройкой
step = lr / epochs  ← Размер шага уменьшается после каждой эпохи
```

```
def lr_scheduler(epochs, lr):  
    ''' Пошаговая скорость усвоения '''  
    return lr - step
```




Рис. 10.8 Скорость усвоения с постоянным шагом

10.3.5 Косинусное закаливание

Метод косинусного закаливания был популярен среди исследователей и часто появляется в научных статьях, посвященных абляционным исследованиям. Он еще называется *циклической скоростью усвоения*. Здесь идея заключается в том, чтобы вместо поступательного снижения скорости усвоения в процессе тренировки делать это в циклах.

Проще говоря, мы начинаем с начальной скорости усвоения и поступательно снижаем ее до более низкой, а затем поступательно снова повышаем. Мы постоянно повторяем этот цикл, но каждый раз скорость, с которой цикл начинается (высокий) и заканчивается (низкий), ниже – и поэтому мы по-прежнему продвигаемся ниже по циклам.

Так в чем же преимущество? Это дает возможность периодически исследовать другие локальные оптимумы (выпрыгивать) и избегать седловых точек. В случае локальных оптимумов это похоже на лучевой поиск. Тренировка, скорее всего, будет выпрыгивать из текущего локального оптимума и начинать погружаться в другой. Хотя поначалу ничто не указывает на то, что новый локальный оптимум лучше, в конце концов он проявит себя. И вот почему. По мере продвижения тренировки мы будем погружаться глубже в более оптимальные оптимумы, чем в менее хорошие. С затухающей верхней скоростью усвоения становится все менее и менее вероятным, что мы выпрыгнем из хорошего локального оптимума. Такое циклическое поведение можно представить и по-другому, как антитезу разведывание–эксплуатация: на верхнем конце цикла тренировка проводит разведку новых путей, а на нижнем – эксплуатирует хорошие пути. По мере того как мы продвигаемся в тренировке вперед, мы все меньше и меньше занимаемся разведкой и все больше и больше эксплуатируем.

Еще одно преимущество заключается в том, что после глубокого погружения в нижний конец цикла скорости усвоения мы можем

застрять в седловой точке. Давайте воспользуемся следующей ниже диаграммой, которая поможет нам разобраться в том, что такое седловая точка.

Если наши признаки (независимые переменные) имеют линейную взаимосвязь с метками (зависимыми переменными), то как только мы обнаружим наклон изменения, мы достигнем глобального оптимума независимо от скорости усвоения (как показано на первой кривой).

С другой стороны, если взаимосвязь является полиномиальной, то мы увидим нечто, более похожее на выпуклую кривую с глобальным оптимумом в качестве нижней точки кривой. В принципе, до тех пор, пока мы будем постоянно снижать скорость усвоения, мы будем опускаться до самой низкой точки, избегая скачков взад-вперед между сторонами кривой (как показано на второй кривой).

Но мощь глубокого обучения заключена в признаках, которые имеют нелинейную (и неполиномиальную) взаимосвязь с метками (как показано на третьей кривой). В этом случае подумайте о пространстве потери, состоящем из долин, вершин и седловых точек, и одна долина является глобальным оптимумом. Наша цель, конечно же, состоит в том, чтобы отыскать эту долину, отсюда и преимущество разведывания нескольких локальных оптимумов (долин).

Седловая точка – это часть пространства потери в долине, которая имеет плато; она выравнивается, прежде чем продолжить спуск. Если наша скорость усвоения будет очень низкой, то мы будем бесконечно скакать по плато. И поэтому, хотя мы хотим, чтобы эта крошечная скорость усвоения приближалась к концу тренировки, мы хотим, чтобы она иногда повышалась, дабы сбивать нас с седловых точек на пути к самой низкой точке.

На рис. 10.9 противопоставлена поверхность потери между линейной/полиномиальной взаимосвязью и нелинейной зависимостью, на которой показаны пики, долины и плато, могущие стать седловой точкой.



Рис. 10.9 Градиентный спуск и наклон скорости изменения

При использовании косинусного затухания в сочетании с ранней остановкой мы должны переосмыслить целевой критерий (вали-

дационная точность) остановки. Если мы тренируемся с нециклическим затуханием, то мы, скорее всего, будем использовать очень малый порог разницы между эпохами, прежде чем остановиться. Но при циклическом поведении мы, скорее всего, будем встречать внезапные всплески разницы (увеличение валидационной потери) во время разведывания (высокий конец цикла). Следовательно, для ранней остановки нам нужно использовать более широкий разрыв. Альтернативой является использование конкретно-прикладной ранней остановки, которая поступательно уменьшает разницу в сочетании с уменьшением верхнего конца цикла.

Ниже приведен пример имплементации планировщика скорости усвоения с использованием косинусного затухания. Эта функция немного сложна. Мы используем функцию косинуса `np.cos()`, чтобы сгенерировать синусоидальную волну от 0 до 1. Например, $\cos(\pi)$ равен -1 , а $\cos(2\pi)$ равен 1 , поэтому вычисление значения для передачи в `np.cos()` кратно π . Для того чтобы значение было положительным, к вычислению добавляется 1 , и результат теперь будет находиться в диапазоне от 0 до 2. Затем это значение уменьшается вдвое (в 0.5 раза), и поэтому теперь результат будет находиться в диапазоне от 0 до 1. Потом затухание корректируется с помощью `alpha`, которая устанавливает нижнюю границу минимальной скорости усвоения.

```
def cosine_decay(epoch, lr, alpha=0.0):
    """ Косинусное затухание
        """
    cosine_decay = 0.5 * (1 + np.cos(np.pi * (e_steps * epoch) / t_steps))
    decayed = (1 - alpha) * cosine_decay + alpha
    return lr * decayed

def lr_scheduler(epochs, lr):
    """ Скорость усвоения на основе косинусного закаливания """
    return cosine_decay(epochs, lr)
```

Вычисляет значение косинуса между 0 и 2 и сокращает наполовину

Возвращает сниженную скорость усвоения

Подсоединяет обратный вызов планировщика скорости усвоения к функции косинусного затухания

Корректирует значение с помощью alpha

В TF 2.x косинусное затухание было добавлено в качестве встроенного планировщика скорости усвоения:

```
from tf.keras.experimental import CosineDecay

lrate = CosineDecay(initial_learning_rate, decay_steps, alpha)

model.fit(x_train, y_train, epochs=epochs, batch_size=batch_size,
          callbacks=[lrate])
```

Импортирует встроенный планировщик скорости усвоения CosineDecay

Инстанцирует планировщик скорости усвоения CosineDecay

Добавляет планировщик скорости усвоения в качестве обратного вызова во время тренировки

10.4 Регуляризация

Следующий важный гиперпараметр – это *регуляризация*. Она относится к методам добавления шума в тренировку в таком ключе, чтобы модель не запоминала тренировочные данные. Чем дольше мы можем откладывать запоминание, тем больше у нас возможностей повысить точность модели во время предсказания на данных, на которых она не тренировалась, таких как тестовые (отложенные) данные.

Давайте сформулируем это проще. Мы хотим, чтобы модель усваивала существенные признаки (обобщение), а не данные (запоминание).

Примечание об отсеке для регуляризации: по секрету, никто больше этого не делает.

10.4.1 Регуляризация весов

Наиболее широко используемой формой регуляризации в настоящее время является *регуляризация весов*, т. н. *затухание весов*. Регуляризация весов применяется на каждом слое. Ее предназначение состоит в том, чтобы добавлять шум к обновлению весов во время обратного распространения относительно размера весов. Этот шум принято называть *штрафом*, и слои с более крупным весом имеют более крупный штраф, чем слои с меньшим весом.

Не углубляясь в градиентный спуск и обратное распространение, достаточно сказать, что калькуляция потери является частью вычисления по обновлению весов в каждом слое. Например, в регрессорной модели мы обычно используем среднеквадратическую ошибку для потери между предсказанными значениями (\hat{y}) и фактическими значениями (фундаментальная истина – y), которую можно обозначить следующим образом:

$$\text{потеря} = \text{MSE}(\hat{y}, y).$$

В целях добавления шума в каждый слой мы хотим добавлять самую малость в качестве штрафа пропорционально размеру весов:

$$\begin{aligned}\text{потеря} &= \text{MSE}(\hat{y}, y) + \text{штраф}; \\ \text{штраф} &= \text{затухание} \times R(w).\end{aligned}$$

Здесь затухание – это затухание весов, то есть значение < 1 , а $R(w)$ – регуляризаторная функция, применяемая к весам w в этом слое. TF.Keras поддерживает следующие регуляризаторные функции:

- *L1* – сумма абсолютных весов, т. н. регуляризация методом Лассо;
- *L2* – сумма квадратических весов, т. н. гребневая регуляризация;

- *L1L2* – сумма абсолютных и квадратических весов, т. н. регуляризация методом эластичной сети.

В абляционных исследованиях, цитируемых в современных исследовательских работах по передовым моделям, используется весовая регуляризация *L2* в диапазоне значений от 0.0005 до 0.001. Исходя из собственного опыта, я обнаружил, что значения выше 0.001 слишком агрессивны в весовой регуляризации, и тренировка не сходится.

В TF.Keras именованный параметр `kernel_regularizer` используется для задания весовой регуляризации для каждого слоя. Если вы используете его, то вы должны указывать его на всех слоях, которые имеют усваиваемые параметры (например, `Conv2D`, `Dense`). Ниже приведен пример имплементации задания регуляризации с затуханием весов *L2* для сверточного слоя (`Conv2D`).

10.4.2 Сглаживание меток

Сглаживание меток заходит к регуляризации с другой стороны. Ранее мы обсуждали методы добавления шума с целью предотвращения запоминания, чтобы модели обобщали на примерах в пределах того же распределения, которое не встречалось моделью во время тренировки.

Однако мы обнаруживаем, что даже когда штрафует эти весовые обновления, чтобы предотвратить запоминание, эти модели, как правило, слишком уверены в своих предсказаниях (высокое значение вероятности).

Когда модель слишком уверена, расстояние между метками фундаментальной и нефундаментальной истины может сильно различаться. При нанесении на график оно, как правило, будет выглядеть скорее как график рассеяния, чем как кластерный график; было бы желательнее, если бы метки фундаментальной истины были сгруппированы вместе, даже если уверенность ниже. На рис. 10.10 изображена слишком уверенная модель, использующая твердые целевые показатели для меток.

Сглаживание меток помогает обобщать модель, делая предсказания менее уверенными, что приводит к тому, что расстояния между фундаментальными и нефундаментальными истинами кластеризуются вместе.

В сглаживании меток мы меняем абсолютную уверенность (1 и 0) меток, кодированных с одним активным состоянием (фундаментальные истины), на нечто меньшее, чем абсолютная уверенность, обозначаемая как α (альфа). Например, вместо того чтобы устанавливать значение 1 (100 %) метки фундаментальной истины, мы устанавливаем его равным чему-то чуть меньшему, например 0.9 (90 %), а затем меняем все нефундаментальные истины с 0 (0 %) на ту же величину, на которую мы снизили метку фундаментальной истины (например, 10 %).



Рис. 10.10 Метки в качестве твердых целевых показателей во время тренировки в виде меток, кодированных с одним активным состоянием (0 или 1)

На рис. 10.11 показано сглаживание меток. На этом изображении предсказания из выводящего плотного слоя сравниваются с метками фундаментальной истины после сглаживания меток, именуемых мягкими целевыми показателями. Потеря рассчитывается по мягким целевым показателям, а не по твердым, что, как было показано на практике, делает расстояния между фундаментальной истиной




Рис. 10.11 Сглаживание меток в качестве мягких целевых показателей, когда метки являются менее чем абсолютно уверенными

и нефундаментальной истиной более упорядоченными. Тогда эти расстояния будут с большей вероятностью образовывать кластеры, что способствует тому, чтобы модель становилась обобщеннее.

В TF 2.x сглаживание меток встроено в функции потери. Для их использования следует инстанцировать соответствующую функцию потери в явной форме и задать именованный параметр `label_smoothing`. На практике коэффициент α поддерживается малым, при этом 0.1 является наиболее широко используемым значением.

```
from tensorflow.keras.losses import CategoricalCrossentropy
```

```
model.compile(loss=CategoricalCrossentropy(label_smoothing=0.1),  
              optimizer='adam', metrics=['acc'])
```

Задаёт сглаживание меток
во время компиляции модели

Далее мы обобщим все, что рассмотрели по гиперпараметрам, и то, как они влияют на достижение оптимального исхода во время тренировки и целевого критерия (например, точности) во время тренировки.

10.5 За пределами компьютерного зрения

Все модельные архитектуры глубокого обучения, независимо от типа данных или сферы деятельности, имеют настраиваемые гиперпараметры. И стратегии их точной настройки одинаковы. Независимо от того, работаете ли вы с компьютерным зрением, пониманием естественного языка или структурированными данными, во всех областях глубокого обучения существуют четыре гиперпараметра: скорость усвоения, затухание скорости усвоения, размер пакета и регуляризация.

Гиперпараметры для регуляризации могут различаться по типу в разных модельных архитектурах и в разных областях. Но зачастую этого не происходит. Например, затухание весов может быть применено к любому слою с усваиваемыми весами, независимо от того, какой является модель: компьютерного зрения, понимания естественного языка или структурированных данных.

Некоторые модельные архитектуры, такие как глубокие нейронные сети и бустированные деревья, имеют свои исторически сложившиеся уникальные гиперпараметры. Например, в случае глубоких нейросетей можно увидеть настройку числа слоев и числа единиц в расчете на слой. В случае бустированных деревьев можно увидеть настройку числа деревьев и листьев. Но с тех пор, как стало принято разделять их на гиперпараметры (для тренировки модели) и метапараметры (для настройки модельной архитектуры), эти настраиваемые параметры теперь называются *метапараметрами*. Поэтому если вы настраиваете число слоев и единиц в сочетании со скоростью

усвоения под глубокую нейронную сеть, то вы, по сути, выполняете макроархитектурный поиск и гиперпараметрическую настройку в параллельном режиме.

Резюме

- Разные весовые распределения и выборки влияют на сходжение во время тренировок.
- Разница между поиском оптимальной инициализации весов (лотерейный принцип) и усвоением оптимальной инициализации весов (разминка) заключается в том, что модель усваивает наилучшую инициализацию, вместо того чтобы находить ее эмпирически.
- Ручной подход к гиперпараметрическому поиску лучше всего использовать, когда набор данных мал и имеет недостаток, заключающийся в том, что вы можете упустить из виду значения гиперпараметров, которые обеспечивают более оптимальный исход во время тренировки.
- Решеточный поиск используется для гиперпараметрической настройки в малом пространстве поиска, а случайный поиск значительно эффективнее в более крупном пространстве поиска.
- Использование KerasTuner для гиперпараметрического поиска позволяет автоматизировать поиск, но имеет тот недостаток, что нельзя управлять поиском вручную.
- Для уменьшения скорости усвоения используются различные алгоритмы, такие как затухание во времени, постоянный шаг, рамповый шаг и косинусное закаливание.
- Настройка планировщика скорости усвоения предусматривает определение функции обратного вызова, имплементацию конкретно-прикладного алгоритма скорости усвоения в функции обратного вызова и добавление функции обратного вызова в метод `fit()`.
- Традиционными подходами к регуляризации являются затухание весов и сглаживание меток.

11

Перенос обучения

Эта глава охватывает следующие ниже темы:

- использование предварительно построенных и преднатренированных моделей из TF.Keras и TensorFlow Hub;
- перенос обучения между задачами в похожих и несовпадающих предметных областях;
- инициализация моделей предметно-специфичными весами для переноса обучения;
- определение того, когда следует реиспользовать высокоразмерное или низкоразмерное латентное пространство.

TensorFlow и TF.Keras поддерживают широкое наличие предварительно построенных и преднатренированных моделей. *Преднатренированные* модели можно использовать как есть, тогда как *предварительно построенные* модели можно тренировать с нуля. Путем замены задачной группы преднатренированные модели тоже могут переконфигурироваться под выполнение любого числа задач. Процесс замены или переконфигурирования задачной группы с помощью перетренировки называется *переносом обучения*.

По сути, перенос обучения означает передачу знаний о решении одной задачи для решения другой задачи. Преимущество переноса обучения по сравнению с тренировкой модели с нуля заключается в том, что новая задача может быть натренирована быстрее и с меньшим объемом данных. Думайте об этом как о форме реиспользования: мы используем модель с усвоенными ею весами повторно.

Вы, возможно, спросите, можно ли реиспользовать веса, усвоенные под одну модельную архитектуру, в другой? Нет, две модели должны иметь одинаковую архитектуру, например ResNet50 для ResNet50. Еще один распространенный вопрос: можно ли реиспользовать усвоенные веса в *любой* другой задаче? Можно, но результаты будут варьироваться в зависимости от уровня сходства между предметной областью преднатренированной модели и новым набором данных. Итак, под усвоенными весами мы на самом деле подразумеваем усвоенные существенные признаки, выделение соответствующих признаков и представление латентного пространства – усвоение представления.

Давайте рассмотрим пару примеров, в которых перенос обучения может приводить, а может и не приводить к желаемым результатам. Допустим, у нас есть преднатренированная модель для видов и сортов фруктов, и у нас есть новый набор данных для видов и сортов овощей. Весьма вероятно, что представления, усвоенные для фруктов, можно реиспользовать для овощей, и нам просто нужно натренировать задачную группу. Но что, если наш новый набор данных состоит из марок и моделей грузовиков и фургонов? В этом случае предметные области набора данных настолько отличаются друг от друга, что очень маловероятно, что представления, усвоенные для фруктов, могут быть реиспользованы для грузовиков и фургонов. В случае похожих предметных областей задача, которую мы хотим, чтобы наша новая модель выполняла, работает в предметной области, похожей на данные, на которых натренирована изначальная модель.

Еще один подход к усвоенным представлениям заключается в использовании модели, натренированной на чрезвычайно разнообразном наборе классов изображений. Многочисленные компании, занимающиеся искусственным интеллектом, предоставляют этот вид услуг по переносу обучения. Как правило, их преднатренированные модели тренируются на десятках тысяч классов изображений. Здесь предполагается, что при таком широком разнообразии некоторая часть усвоенного представления может реиспользоваться в любом произвольном новом наборе данных. Недостатком данного подхода является то, что для охвата такого широкого разнообразия латентное пространство должно быть очень крупным – и поэтому в итоге вы получаете очень крупную (сверхпараметризованную) модель в задачной группе.

Третий подход заключается в том, чтобы найти золотую середину между двумя подходами, параметрически эффективной натренированной на узкой предметной области моделью и массивно натренированной моделью. Модельные архитектуры, такие как ResNet50 и, совсем недавно, EfficientNet-B7, преднатренированы на наборе данных ImageNet, состоящем из разнообразной коллекции из 1000 классов. Указанные модели нередко используются в самодельных проектах по переносу обучения. Модель ResNet50, например, имеет достаточно эффективное, но довольно крупное латентное простран-

ство перед задачным компонентом для цели переноса обучения на широкий спектр наборов данных для классифицирования изображений; ее латентное пространство состоит из 2048 карт признаков размера 4×4 .

Давайте подытожим эти три подхода:

- передача похожей предметной области:
 - параметрически эффективная натренированная на узкой предметной области модель;
 - перетренировывает новый задачный компонент;
- передача несовпадающей предметной области:
 - параметрически сверхъёмкостная натренированная на узкой предметной области модель;
 - перетренировывает новый задачный компонент с тонкой настройкой других компонентов;
- общая передача:
 - параметрически сверхъёмкостная натренированная на общей предметной области модель;
 - перетренировывает новый задачный компонент.

Преднатренированная модель также может реиспользоваться в переносе обучения для усвоения задач, отличных от преднатренированной модели. Например, предположим, что у нас есть преднатренированная модель, которая классифицирует архитектурный стиль по фотографиям фасада дома. И давайте предположим, что теперь мы хотим научиться предсказывать продажную цену дома. Весьма вероятно, что существенные признаки, выделение признаков и латентное пространство будут переданы задаче другого типа, такой как регрессор, – модели, которая выдает одно действительное число (например, продажную цену дома). Этот тип переноса обучения на другой тип задачи, как правило, возможен, если другой тип задачи также может быть натренирован с использованием изначального набора данных.

В этой главе рассматривается получение предварительно построенных и преднатренированных передовых моделей из общедоступных ресурсов: TF.Keras и TensorFlow Hub. Затем я расскажу вам об использовании этих моделей «прямо из коробки». И наконец, вы узнаете о различных способах использования преднатренированных моделей для переноса обучения.

11.1 Предварительно построенные модели TF.Keras

Вычислительный каркас TF.Keras поставляется с предварительно построенными моделями, которые можно использовать как есть для тренировки новой модели либо модифицировать и/или тонко настраивать под перенос обучения. Они основаны на лучших в своем

классе моделях классифицирования изображений, моделях, отмеченных наградами на таких конкурсах, как ImageNet, которые часто цитируются в исследовательских работах по глубокому обучению.

Документацию по предварительно построенным моделям Keras можно найти на веб-сайте Keras (<https://keras.io/api/applications/>). В табл. 11.1 перечислены архитектуры предварительно построенных моделей Keras.

Таблица 11.1. Предварительно построенные модели Keras

Тип модели	Архитектура передовой (SOTA) модели
Последовательная CNN	VGG16, VGG19
Остаточная CNN	ResNet, ResNet v2
Широкая остаточная CNN	ResNeXt, Inception v3, InceptionResNet v2
Альтернативно соединенная CNN	DenseNet, Xception, NASNet
Мобильная CNN	MobileNet, MobileNet v2

Предварительно построенные модели Keras импортируются из модуля `keras.applications`. Ниже приведены примеры предварительно построенных передовых моделей, которые можно импортировать. Например, если вы хотите использовать VGG16, то просто замените VGG19 на VGG16. Некоторые модельные архитектуры можно выбирать с разным числом слоев, например VGG, ResNet, Resnext и DenseNet.

```
from tensorflow.keras.applications import VGG19
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.applications import InceptionV3
from tensorflow.keras.applications import InceptionResNetV2
from tensorflow.keras.applications import DenseNet121
from tensorflow.keras.applications import DenseNet169
from tensorflow.keras.applications import DenseNet201
from tensorflow.keras.applications import Xception
from tensorflow.keras.applications import NASNetLarge
from tensorflow.keras.applications import NASNetMobile
from tensorflow.keras.applications import MobileNet
```

11.1.1 Базовая модель

По умолчанию предварительно построенные модели TF.Keras являются полными, но ненадтренированными, то есть веса и смещения инициализированы случайным образом. Каждая ненадтренированная предварительно построенная сверточная нейросетевая модель сконфигурирована под определенную входную форму (см. документацию) и число выходных классов. В большинстве случаев входная форма составляет либо (224, 224, 3), либо (299, 299, 3). Модели также будут принимать входные данные в формате «сначала канал», как в (3, 224, 224) и (3, 299, 299). Число выходных классов обычно равно 1000, то есть модели могут выявлять 1000 распространенных меток

изображений. Эти предварительно построенные, но ненадтренированные модели не будут вам столь полезны в том виде, в каком они есть, так как вам пришлось бы проводить их полную тренировку на наборе данных с одинаковым числом меток (1000). Важно знать, что, собственно говоря, содержится в этих предварительно построенных моделях, чтобы иметь возможность их переконфигурировать преднатренированными весами, новыми задачными компонентами либо тем и другим. В этой главе мы рассмотрим все три упомянутые следующие переконфигурации.

На рис. 11.1 показана архитектура предварительно построенной сверточной нейросетевой модели. Архитектура состоит из стержневой сверточной группы, предустановленной под входную форму, одной для нескольких сверточных групп (ученика), бутылочного слоя и классификаторного слоя, предустановленного под 1000 классов.

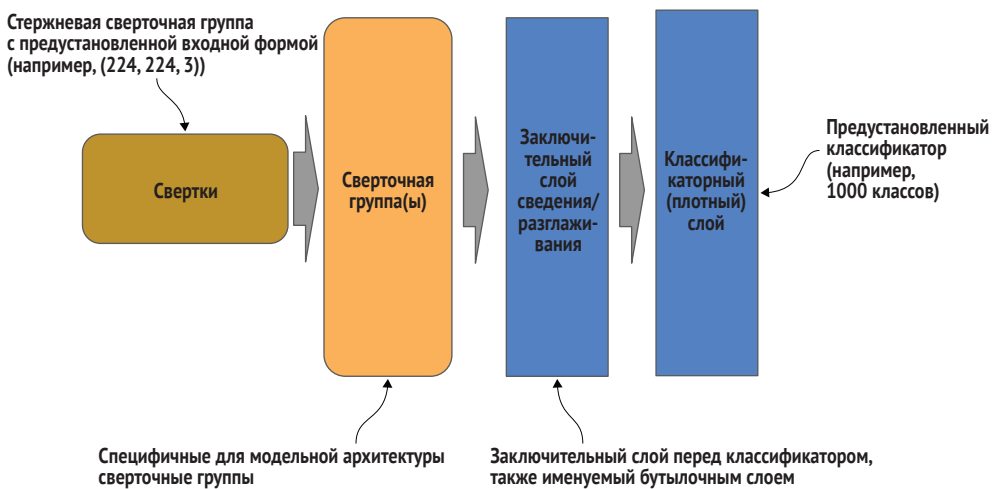


Рис. 11.1 Архитектура предварительно построенной сверточной нейросетевой модели со слоями задачной группы (темно-серого цвета)

В предварительно построенных моделях нет назначенной им функции потери и оптимизатора. Перед их использованием мы должны выполнить метод `compile()`, чтобы назначить потерю, оптимизатор и меры измерения производительности. В следующем ниже примере исходного кода мы сначала импортируем, а затем инстанцируем предварительно построенную модель `ResNet50`, потом компилируем модель:

```
from tensorflow.keras.applications import ResNet50

model = ResNet50()
model.compile(loss='categorical_crossentropy', optimizer='adam',
              metrics=['accuracy'])
```

Получает полную и ненадтренированную предварительно построенную модель `ResNet50`

Компилирует модель для тренировки в качестве классификатора набора данных

Применение предварительно построенных моделей в таком ключе имеет довольно лимитированный характер, учитывая не только фиксированный размер входных данных, но и число категорий классификатора, которое равно 1000. Маловероятно, что вы ограничитесь конфигурацией, заданной по умолчанию, чтобы вы ни намеревались сделать. Далее мы рассмотрим способы конфигурирования предварительно построенных моделей под выполнение различных задач.

11.1.2 Преднатренированные на ImageNet модели для предсказаний

Все предварительно построенные модели поставляются с весами и смещениями, преднатренированными на основе набора данных ImageNet 2012, который содержит 1.2 млн изображений в 1000 классах. Если вам нужно предсказывать, просто что изображение входит или не входит в 1000 классов набора данных ImageNet, то вы можете использовать преднатренированные и предварительно построенные модели как есть. Попарное соотнесение идентификаторов меток с именами классов можно найти на GitHub (<https://gist.github.com/yrevar/942d3a0ac09ec9e5eb3a>). Примеры классов включают такие вещи, как белоголовый орлан, туалетная бумага, клубника и воздушный шар.

Давайте воспользуемся предварительно построенной моделью ResNet, преднатренированной весами ImageNet, для классифицирования (или предсказания) изображения слона. Ниже приведен соответствующий процесс в пошаговом режиме.

- 1 Метод `preprocess_input()` предобрабатывает изображение в соответствии с методом, используемым предварительно построенной моделью ResNet.
- 2 Метод `decode_predictions()` попарно соотносит идентификаторы меток с именем класса.
- 3 Предварительно построенная модель ResNet инстанцируется весами ImageNet.
- 4 Изображение слона считывается библиотекой OpenCV, а потом его размер изменяется, становясь (224, 224), чтобы соответствовать входной форме модели.
- 5 Затем изображение предобрабатывается с помощью метода `preprocessed_input()` модели.
- 6 Далее изображение реформируется в пакет.
- 7 Затем изображение классифицируется моделью с помощью метода `predict()`.
- 8 Три верхние предсказанные метки потом соотносятся с именами их классов с помощью функции `decode_predictions()` и печатаются. В этом примере мы могли бы увидеть вывод «африканский слон» в качестве главного предсказания.

На рис. 11.2 изображена преднатренированная модель TF.Keras с сопутствующими функциями предобработки входных данных и постобработки выходных данных.

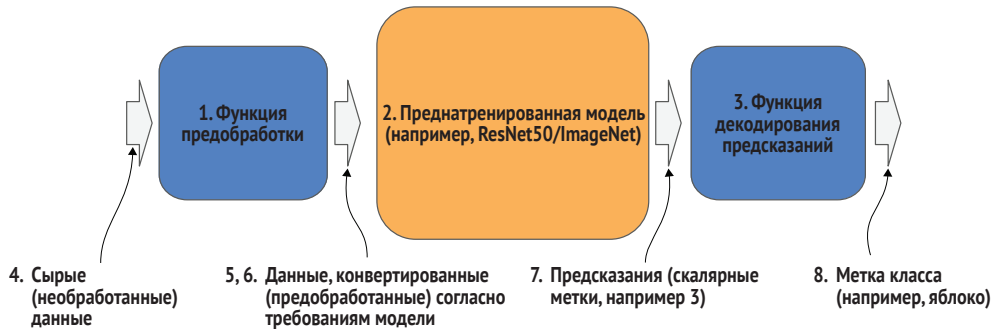
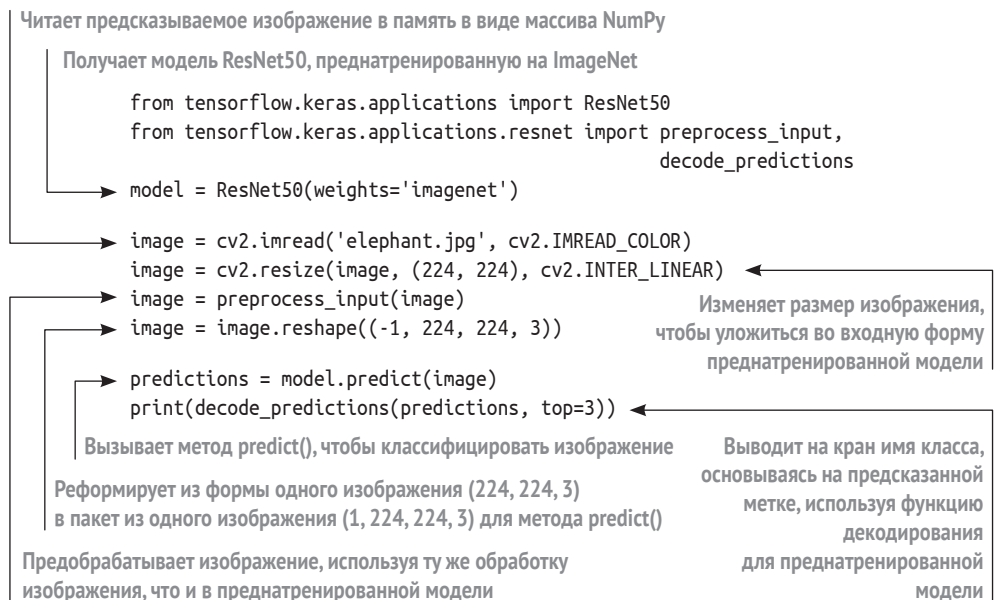


Рис. 11.2 Преднатренированная модель TF.Keras с сопутствующими модельно-специфичными функциями предобработки входных данных и постобработки выходных данных

Теперь давайте посмотрим, как закодировать этот процесс:



11.1.3 Новый классификатор

Заключительный классификаторный слой во всех предварительно построенных моделях можно удалять и заменять новым классификатором, а также другой задачей, такой как регрессор. Затем новый классификатор можно использовать для тренировки предварительно построенной модели на новом наборе данных и наборе классов. На-

пример, если бы у вас был набор данных о 20 классах блюд из лапши, то вы бы просто удалили существующий классификаторный слой, заменили его новым классификаторным слоем с 20 узлами, скомпилировали модель и натренировали ее набором данных о блюдах из лапши.

Во всех предварительно построенных моделях классификаторный слой называется *верхним слоем*. В предварительно построенных моделях TF.Keras входная форма по умолчанию равна (224, 224, 3), а число классов в выходном слое равно 1000. При инстанцировании предварительно построенной модели TF.Keras вы бы установили параметр `include_top` равным `False`, чтобы получить экземпляр модели без классификаторного слоя. Кроме того, при `include_top=False` можно указать другую входную форму модели с помощью параметра `input_shape`.

Теперь давайте опишем этот процесс и его применение в контексте нашего классификатора 20 блюд из лапши. Допустим, у вас есть лапшичный ресторан, и поварской персонал постоянно выкладывает различные свежеприготовленные блюда из лапши на стойке заказа. Клиент может выбрать любое блюдо, и для простоты предположим, что все блюда из лапши имеют одинаковую цену. Кассиру просто нужно подсчитать число блюд из лапши. Но вам все еще нужно решить несколько проблем. Иногда ваш поварской персонал готовит слишком много одного или нескольких блюд, и они остывают, так что их приходится выбрасывать, вследствие чего вы теряете выручку. В других случаях ваш поварской персонал готовит слишком мало одного или нескольких блюд, и клиенты переходят в другой ресторан, потому что их блюдо отсутствовало – характерный случай потери возможности.

В целях решения обеих проблем вы планируете разместить одну камеру на кассе, а другую – в зоне приготовления пищи, где выбрасываются остывшие блюда из лапши. Вы хотите, чтобы камеры классифицировали в реальном времени как купленные блюда из лапши, так и выброшенные и выводили эту информацию поварам, чтобы те могли лучше оценивать, какие блюда следует готовить.

Давайте приступим к осуществлению вашего плана. Прежде всего, поскольку вы уже работаете в лапшичном ресторане, вы нанимаете кого-то фотографировать блюда, размещенные на стойке заказа. Когда делается снимок, шеф-повар выкрикивает название блюда, которое записывается вместе с фотографией. Допустим, в конце рабочего дня ваш объем составляет 500 блюд с лапшой. И допустим, у вас довольно ровное распределение блюд, что даст вам в среднем 25 снимков на блюдо из лапши. Это число, возможно, покажется небольшим для каждого класса, но поскольку это ваши блюда, а фон всегда один и тот же, то этого, вероятно, будет достаточно. Теперь вам нужно просто пометить снимки аудиозаписями.

Итак, вы готовы к тренировке. Вы получаете предварительно построенную модель из TF.Keras и указываете `include_top=False`, чтобы

удалить плотный классификаторный слой на 1000 классов, который впоследствии замените плотным слоем из 20 узлов. Вы хотите, чтобы ваша модель предсказывала быстро, потому что вы перемещаете много блюд из лапши, и вы хотите сократить число параметров без отрицательного влияния на точность модели. Вместо того чтобы предсказывать размер ImageNet (224, 224, 3), вы указываете `input_shape=(100, 100, 3)`, чтобы изменить вектор на входе в модель на размер (100, 100, 3).

Мы также могли бы удалить заключительный слой сведения/разглаживания (бутылочный слой) в предварительно построенной модели, чтобы заменить его вашим собственным, установив параметр `pooling=None`.

На рис. 11.3 показана переконфигурируемая архитектура предварительно построенной сверточной нейросетевой модели. Она состоит из стержневой сверточной группы, входной размер которой можно конфигурировать, одной или нескольких сверточных групп (ученика) и опционально конфигурируемого бутылочного слоя.

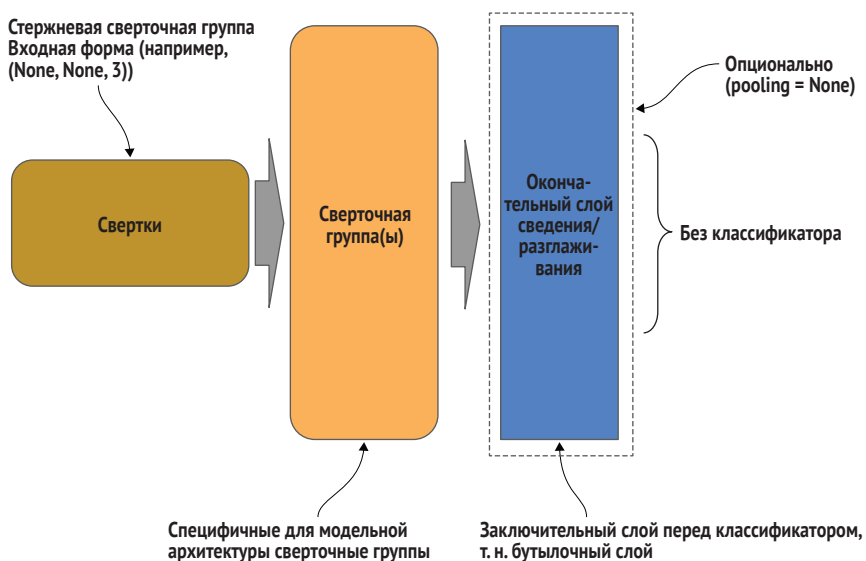


Рис. 11.3 В этой реконфигурируемой предварительно построенной модельной архитектуре без классификаторного слоя оставлять слои сведения не обязательно

Если говорить о входной форме, то в документации в отношении предварительно построенных моделей имеется лимит на минимальный размер входной формы. Для большинства моделей это (32, 32, 3). Обычно я не советую использовать предварительно построенные модели в таком ключе, потому что для большинства этих архитектур окончательные карты признаков перед слоем глобального-среднего сведения (бутылочным слоем) будут (однопиксельными) картами

признаков 1×1 – по существу, теряя все пространственные взаимосвязи. Однако исследователи обнаружили, что при использовании с изображениями CIFAR-10 и CIFAR-100, размер которых (32, 32, 3), они способны отыскивать хорошие гиперпараметрические настройки, прежде чем продвигаться вперед к наборам изображений конкурсного уровня (например, ImageNet) с размерами (224, 224, 3).

В следующем ниже исходном коде мы создаем экземпляр предварительно построенной модели ResNet50 и заменяем ее на новый классификатор для нашего примера с 20 блюдами из лапши.

- 1 Мы удаляем существующий классификатор из 1000 узлов параметром `include_top=False`.
- 2 Устанавливаем входную форму равной (100, 100, 3) параметром `input_shape` для нашего меньшего входного размера.
- 3 Мы решаем оставить заключительный слой сведения/разглаживания (бутылочный слой) в качестве слоя глобального среднего сведения с помощью параметра `pooling`.
- 4 Добавляем назад замещающий плотный слой с 20 узлами, соответствующими числу блюд из лапши, и активационной функции `softmax` в качестве верхнего слоя.
 - Последним (выходным) слоем в предварительно построенной модели ResNet50 является слой `model.output`. Он соответствует бутылочному слою, так как мы отказались от классификатора, заданного по умолчанию.
 - Мы привязываем предварительно построенную модель ResNet50 `model.output` в качестве входных данных к нашему замещающему плотному слою.
- 5 Мы строим модель. Входом является вход в модель ResNet, то есть `models.input`.
- 6 Наконец, компилируем модель для тренировки и задаем функцию потерь как `categorical_crossentropy` и оптимизатор как `adam`, в качестве наилучшей практики для модели классифицирования изображений.

```
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.layers import Dense
```

```
model = ResNet50(include_top=False, input_shape=(100, 100, 3), pooling='avg') ←
```

```
outputs = Dense(20, activation='softmax')(model.output)
model = Model(model.input, outputs)
```

```
model.compile(loss='categorical_crossentropy', optimizer='adam',
              metrics=['accuracy'])
```

Компилирует модель для тренировки

Добавляет классификатор 20 классов

Получает предварительно построенную модель для входной формы (100, 100, 3) и без заключительного классификатора

В большинстве предварительно построенных моделей TF.Keras бутылочным слоем является слой глобального среднего сведения. Этот слой действует для карт признаков как заключительный слой све-

дения и как операция разглаживания, которая конвертирует карты признаков в 1-мерный вектор. В некоторых случаях мы, возможно, захотим заменить этот слой нашим собственным конкретно-прикладным заключительным слоем сведения/разглаживания. В этом случае мы либо указываем параметр `pooling=None` либо не указываем его, что является настройкой, заданной по умолчанию. Тогда зачем мы могли бы это делать?

Для того чтобы ответить на этот вопрос, давайте вернемся к нашим блюдам из лапши. Давайте предположим, что, натренировав модель, вы получили точность 92 % и хотите добиться большего. Сперва вы решаете добавить обогащение (аугментацию) изображения. Ну, мы, вероятно, не будем заморачиваться горизонтальным переворотом, так как блюдо из лапши никогда не будет располагаться вверх тормашками! Вертикальный переворот, вероятно, тоже не поможет, так как чаша с лапшой выглядит довольно однородно (без зеркального отражения). Мы можем пропустить поворот, поскольку чаша с лапшой довольно однородна, и мы пропускаем масштабирование, так как положение камеры относительно посуды фиксировано. Хм, итак, вы спрашиваете, что же осталось?

Как насчет местоположения чаши, так как чаши будут перемещаться на кассе и на прилавках для раздачи? Вы делаете это и получаете точность 94 %. Но вы хотите еще большей точности. По наитию мы выдвигаем предположение, что, возможно, в признаковой информации что-то упускается, когда каждая заключительная карта признаков сокращается до одного пиксела для разглаживания в 1-мерный вектор путем заданного по умолчанию сведения `GlobalAveragePooling2D`. Вы смотрите на сводную информацию о своей модели и видите, что размер окончательных карт признаков составляет 4×4. Поэтому вы решаете отказаться от заданного по умолчанию сведения и заменить его на `MaxPooling2D` с шагом 2, в результате чего каждая карта признаков будет сокращена до 2×2.4 пикселей вместо одного пиксела, а затем выполняете разглаживание в 1-мерный вектор.

В данном примере исходного кода для нашего классификатора 20 блюд из лапши мы заменяем бутылочный слой максимальным сведением (`outputs = MaxPooling2D(model.outputs)`) и выравниванием (`outputs = Flatten(outputs)`):

```
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.layers import Dense, Flatten
from tensorflow.keras import Model
```

Получает предварительно
построенную модель для
входной формы (100,100,3)
и без классификаторной группы

```
model = ResNet50(include_top=False, input_shape=(100, 100, 3), pooling=None) ←
```

```
outputs = MaxPooling2D(model.output)
outputs = Flatten()(outputs)
outputs = Dense(20, activation='softmax')(outputs) ←
```

Сводит и разглаживает карты
признаков в 1-мерный вектор

Добавляет классификатор
20 классов

```
model = Model(model.input, outputs)
model.compile(loss='categorical_crossentropy', optimizer='adam',
               metrics=['accuracy'])
```


В данном разделе мы рассмотрели предварительно построенные и преднатренированные модели из TF.Keras. Подводя итог, предварительно построенная модель – это существующая модель, обычно основанная на передовой архитектуре, входную форму и задачу которой можно переконфигурировать и веса которой не натренированы. Предварительно построенная модель обычно используется для тренировки модели с нуля, имеет преимущество реиспользования и может переконфигурироваться в соответствии с вашим набором данных и задачей. Ее недостатком является то, что архитектура может не соответствовать вашему набору данных / задаче, поэтому в итоге вы получите модель, менее эффективную по размеру и менее точную.

Преднатренированная модель по сути полностью совпадает, за исключением того, что веса были преднатренированы другим набором данных, например из набора данных ImageNet. Преднатренированные модели используются для предсказания «прямо из коробки» либо для переноса обучения и имеют преимущество реиспользования усвоенного представления для более быстрой тренировки новых наборов данных / задач с меньшим объемом данных. Ее недостатком является то, что преднатренированное усвоение представления, возможно, не будет очень хорошо подходить к предметной области вашего набора данных / задачи.

В следующем далее разделе мы рассмотрим те же концепции, используя предварительно построенные модели из репозитория TensorFlow Hub.

11.2 *Предварительно построенные модели TF Hub*

TensorFlow Hub, или TF Hub, представляет собой общедоступный репозиторий с открытым исходным кодом предварительно построенных и преднатренированных моделей, значительно более обширный, чем TF.Keras. Предварительно построенные/преднатренированные модели TF.Keras хороши для усвоения и практики переноса обучения, но слишком ограничены в предложениях для производственных целей. TF Hub состоит из значительно большего числа предварительно построенных передовых архитектур, обширной категории задач, преднатренированных весов, являющихся специфичными для предметных областей, и публичных предложений, помимо моделей, предоставляемых непосредственно организацией TensorFlow.

В этом разделе рассматриваются предварительно построенные модели для классифицирования изображений. TF Hub предлагает две версии каждой модели, которые описываются следующим образом:

- модули для классифицирования изображений с конкретными классами, под которые модуль был натренирован. Этот процесс является таким же, как и для преднатренированных моделей;

- модули для выделения векторов признаков изображений (бутылочных значений) для использования в конкретно-прикладных классификаторах изображений. Эти классификаторы являются такими же, как и новый классификатор, который мы описали для TF.Keras.

Мы будем работать с двумя предварительно построенными моделями, одна из которых выполняет классифицирование «прямо из коробки», а другая – перенос обучения. Мы скачаем их из репозитория предварительно построенных моделей с открытым исходным кодом Tensor-Flow Hub, который находится по адресу www.tensorflow.org/hub.

В целях использования TF Hub сначала необходимо установить модуль `tensorflow_hub` языка Python:

```
pip install tensorflow_hub
```

В вашем скрипте Python вы обращаетесь к TF Hub, импортируя модуль `tensorflow_hub`:

```
import tensorflow_hub as hub
```

Теперь все готово, чтобы скачать две наши модели.

11.2.1 Применение преднатренированных моделей TF Hub

TF Hub также очень универсален, по сравнению с TF.Keras, в отношении типов модельных форматов, которые можно загружать:

- *TF2.x SavedModel* – используется в качестве локального формата, формата REST или микрослужбы в облаке, настольном компьютере / ноутбуке или рабочей станции;
- *TF Lite* – применяется в качестве службы приложений на мобильном устройстве или устройстве интернета вещей с ограниченным объемом памяти;
- *TF.js* – используется в браузерном приложении на стороне клиента;
- *Coral* – оптимизирован под использование в качестве службы приложений на устройстве Coral Edge / интернета вещей.

В этом разделе мы рассмотрим модели только в формате TF 2.x SavedModel. В целях загрузки модели вы будете выполнять следующие ниже действия.

- 1 Получить URL-адрес модели-классификатора изображений в репозитории TF Hub.
- 2 Извлечь модельные данные из хранилища, указанного в URL-адресе с помощью `hub.KerasLayer()`.
- 3 Построить модель формата TF.Keras SavedModel из модельных данных с помощью последовательного API TF.Keras.
- 4 Задать входную форму равной (224, 224, 3), которая соответствует входной форме базы данных ImageNet, на которой была натренирована преднатренированная модель.

Местоположение модельных данных в репозитории TF Hub для ResNet50 v2

```
model_url = "https://tfhub.dev/google/imagenet/resnet_v2_50/
classification/4"
```

```
model = tf.keras.Sequential([hub.KerasLayer(model_url,
                                             input_shape=(224,224,3))])
```

Извлекает модельные данные и строит модель формата SavedModel

После выполнения метода `model.summary()` результат будет выглядеть следующим образом:

Layer (type)	Output Shape	Param #
keras_layer_7 (KerasLayer)	(None, 1001)	25615849
Total params: 25,615,849		
Trainable params: 0		
Non-trainable params: 25,615,849		

Теперь можно использовать модель, чтобы делать предсказания, то есть выполнять предсказательный вывод. На рис. 11.4 показаны следующие шаги по использованию модели TF Hub, преднатренированной на ImageNet, для предсказаний:

1. получить информацию о метках (именах классов) для ImageNet, чтобы иметь возможность конвертировать предсказанную метку (числовой индекс) в имя класса;
2. предобработать изображения для предсказания:
 - изменить размер входного изображения, чтобы оно совпадало с входными данными модели: (224, 224, 3);
 - нормализовать изображения: разделить на 255;

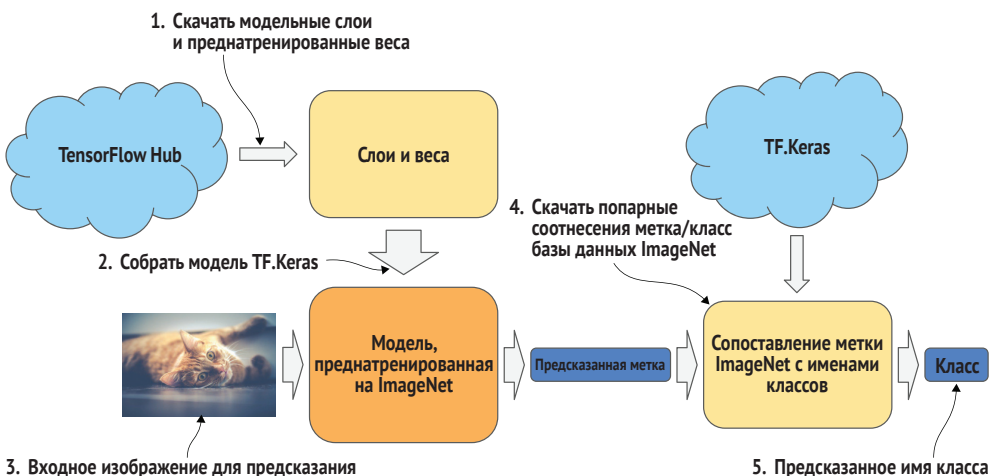


Рис. 11.4 Использование преднатренированной на ImageNet модели TF Hub для предсказания метки, а затем использование попарных соотношений ImageNet для вывода на экран предсказанного имени класса

- 3 вызвать функцию `predict()` для изображений;
- 4 использовать функцию `np.argmax()`, чтобы возвращать индекс метки с наибольшей вероятностью;
- 5 конвертировать предсказанный индекс метки в соответствующее имя класса.

Ниже приведен пример имплементации этих пяти шагов.

```
url = 'https://storage.googleapis.com/download.tensorflow.org/data/
ImageNetLabels.txt'
path = tf.keras.utils.get_file('ImageNetLabels.txt', url)
imagenet_labels = np.array(open(path).read().splitlines())

import cv2
import numpy as np

data = cv2.imread('apple.png')
data = cv2.resize(data, (224, 224))
data = (data / 255.0).astype(np.float32)

p = model.predict(np.asarray([data]))
y = np.argmax(p)

print(imagenet_labels[y])
```

Получает результат конверсии из индекса метки ImageNet в имена классов

Предобрабатывает изображение для предсказания

Делает предсказание с помощью модели

Конвертирует индекс предсказанной метки в имя класса

11.2.2 Новый классификатор

В целях строительства новых классификаторов для преднатренированных моделей мы берем URL-адрес и загружаем оттуда соответствующую модель, обозначаемую как версия модели в виде *признакового вектора*. Указанная версия загружает преднатренированную модель без вершины модели, или классификатора. Это позволяет добавлять свою собственную вершину, или задачуную группу. Выходом из модели является выходной слой. Можно также указать новую входную форму, которая отличается от входной формы, заданной по умолчанию для модели TF Hub.

Ниже приведен пример имплементации загрузки признаково-векторной версии преднатренированной модели ResNet50 v2, в которую мы добавим наш собственный задачный компонент для тренировки модели на данных CIFAR-10. Поскольку наш входной размер для CIFAR-10 отличается от версии TF Hub для ResNet50 v2, которая равна (224, 224, 3), то мы также опционально укажем входную форму:

- 1 получить URL-адрес модели-классификатора изображений в репозитории TF Hub;
- 2 использовать `hub.KerasLayer()` для извлечения модельных данных из репозитория, указанного в URL-адресе;
- 3 указать новую входную форму (32, 32, 3) для набора данных CIFAR-10.

Местоположение версии модели в виде признакового вектора для ResNet50 v2 в репозитории TF Hub

→ `f_url = "https://tfhub.dev/google/imagenet/resnet_v2_50/feature_vector/4"`

`f_layer = hub.KerasLayer(f_url, input_shape=(32,32,3))` ←

Извлекает модельные данные в виде слоя
TF.Keras и задает входную форму

Ниже приведен пример имплементации строительства нового классификатора данных CIFAR-10 в формате SavedModel.

- 1 Создать модель в формате SavedModel с помощью последовательного API.
 - Указать признаково-векторную версию преднатренированной ResNet v2 в качестве низа модели.
 - Указать плотный слой из 10 узлов (по одному на класс CIFAR-10) в качестве вершины модели.
- 2 Скомпилировать модель.

```
model = tf.keras.Sequential([
    f_layer,
    Dense(10, activation='softmax')
])
model.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
              metrics=['acc'])
```

После выполнения метода `model.summary()` результат будет выглядеть следующим образом:

Layer (type)	Output Shape	Param #
keras_layer_4 (KerasLayer)	(None, 2048)	23561152
dense_2 (Dense)	(None, 10)	20490

=====
 Total params: 23,581,642
 Trainable params: 20,490
 Non-trainable params: 23,561,152

Ранее мы рассматривали использование преднатренированных моделей для выполнения предсказаний «прямо из коробки» и использования переконфигурируемых предварительно построенных моделей для более удобной тренировки новых моделей. Далее рассмотрим способы применения и переконфигурирования преднатренированных моделей для более эффективной тренировки и использования меньшего объема данных для новых задач.

11.3 Перенос обучения между предметными областями

В переносе обучения мы используем модели, преднатренированные под одну задачу, и перетренировываем классификатор и/или тонко настраиваем слои под новую задачу. Этот процесс аналогичен тому, что мы только что сделали с построением нового классификатора поверх предварительно построенной модели, но в остальном полностью натренировали модель с нуля.

Перенос обучения имеет два общих подхода:

- *похожие задачи* – преднатренированный набор данных и новый набор данных относятся к аналогичным предметным областям (таким как фрукты и овощи);
- *несовпадающие задачи* – преднатренированный набор данных и новый набор данных относятся к разным предметным областям (таким как фрукты и грузовики/фургоны).

11.3.1 Похожие задачи

Как обсуждалось ранее в этой главе, при выборе подхода учитывается сходство источниковой (преднатренированной) предметной области изображений и адресатной (новой) предметной области. Чем больше сходства, тем больше существующих нижних слоев мы можем реиспользовать без перетренировки. Например, если бы у нас была модель, натренированная на фруктах, то вполне вероятно, что все нижние слои преднатренированной модели можно было бы реиспользовать без перетренировки, чтобы построить новую модель распознавания овощей.

Мы исходим из допущения, что грубые и детализированные признаки, усвоенные в нижних слоях, будут одинаковыми для нового классификатора и могут реиспользоваться как есть перед местом, куда будет добавлен самый верхний слой(и) классифицирования. Давайте рассмотрим причины, по которым мы могли бы предположить, что фрукты и овощи относятся к очень похожим предметным областям. И то, и другое – натуральная пища. Хотя фрукты обычно растут над землей, а овощи – под землей, тем не менее имеют схожие физические характеристики по форме и текстуре, а также по внешним атрибутам, таким как стебли и листья.

Когда источниковая и адресатная предметные области имеют столь высокий уровень сходства, обычно можно заменить существующий верхний классификаторный слой новым классификаторным слоем, заморозить нижние слои и натренировать только классификаторный слой. Поскольку нам не нужно усваивать веса/смещения для других

слоев, обычно можно натренировать модель под новую предметную область с существенно меньшим объемом данных и меньшим числом эпох.

Хотя наличие большего объема данных всегда лучше, перенос обучения между похожими источниковой и адресатной предметными областями обеспечивает возможность тренировки с существенно меньшими наборами данных. Ниже приведены две рекомендации по минимальному размеру набора данных:

- каждый класс (метка) составляет 10 % от размера в источнике наборе данных;
- каждый класс (метка) содержит не менее 100 изображений.

В отличие от метода, показанного для нового классификатора, мы модифицируем исходный код, чтобы заморозить все слои, предшествующие самому верхнему классификаторному слою, перед тренировкой. Замораживание предотвращает обновление (перетренировку) весов/смещений этого слоя (слоев) во время тренировки классификатора (самого верхнего) слоя. В TF.Keras каждый слой имеет свойство `trainable` (тренируемый), которое по умолчанию равно `True`.

На рис. 11.5 показана перетренировка в классификаторном слое преднатренированной модели; ниже приведены соответствующие шаги.

- 1 Использовать предварительно построенную модель с преднатренированными весами/смещениями (ImageNet 2012).
- 2 Удалить существующий классификатор из предварительно построенной модели (самый верхний слой).
- 3 Заморозить оставшиеся слои.
- 4 Добавить новый классификаторный слой.
- 5 Натренировать модель посредством переноса обучения.

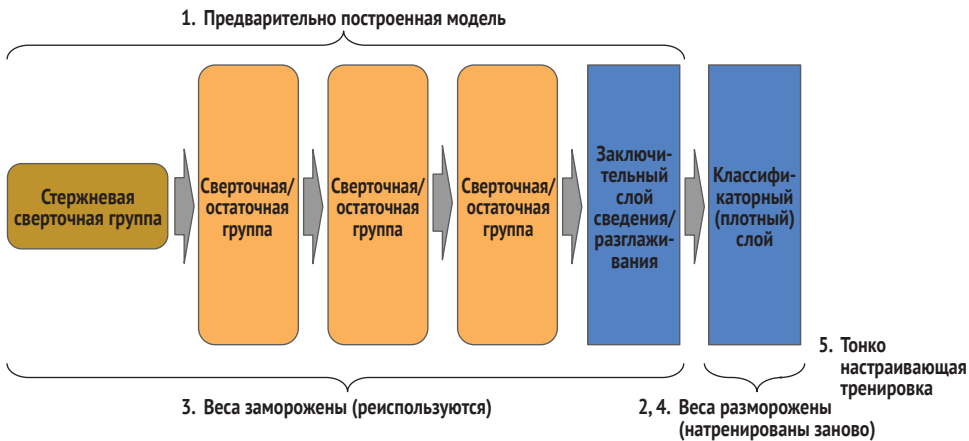


Рис. 11.5 Когда источниковая и адресатная предметные области похожи, перетренировываются только веса классификатора, в то время как остальные нижние веса модели замораживаются

Ниже приведен пример имплементации:

```
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.layers import Dense
from tensorflow.keras import Model

model = ResNet50(include_top=False, pooling='avg', weights='imagenet')

for layer in model.layers:
    layer.trainable = False

output = Dense(20, activation='softmax')(model.output)

model = Model(model.input, output)
model.compile(loss='categorical_crossentropy', optimizer='adam',
              metrics=['accuracy'])
```

Получает преднатренированную модель без классификатора и оставляет слой глобального среднего сведения

Замораживает веса оставшегося слоя

Добавляет классификатор 20 классов

Компилирует модель для тренировки

Обратите внимание, что в этом примере исходного кода мы удержали изначальную входную форму (224, 224, 3). Как показывает практика, если изменить входную форму, то ранее существовавшие натренированные веса/смещения не будут соответствовать разрешающей способности выделения признаков, на которых они были натренированы. В такой ситуации лучше трактовать это как случай несовпадающей задачи.

11.3.2 Несовпадающие задачи

Когда источниковая и адресатная предметные области наборов изображений отличаются, как, например, в нашем примере фруктов и грузовиков/фургонов, то мы начинаем с тех же шагов, что и в предыдущем аналогичном подходе к задаче, но затем выполняем тонкую настройку нижних слоев. Указанные шаги изображены на рис. 11.6 и, как правило, таковы:

- 1 добавить новый классификаторный слой и заморозить оставшиеся нижние слои;
- 2 натренировать новый классификаторный слой в течение целевого числа эпох;
- 3 повторять для тонкой настройки:
 - разморозить следующую самую нижнюю сверточную группу (двигаясь в направлении сверху вниз);
 - натренировать в течение нескольких эпох, чтобы тонко настроить;
- 4 после тонкой настройки сверточных групп:
 - разморозить сверточную стержневую группу;
 - натренировать в течение нескольких эпох, чтобы тонко настроить.

На рис. 11.6 изображены циклы тренировки в шагах 2–4: классификатор перетренировывается в цикле 1, сверточные группы тонко настраиваются в последовательном порядке в циклах 2–4, и стержень настраивается в цикле 5. Обратите внимание, что это отличает

ся от случаев, когда источниковая и адресатная предметные области похожи, и мы тонко настраиваем только классификатор.

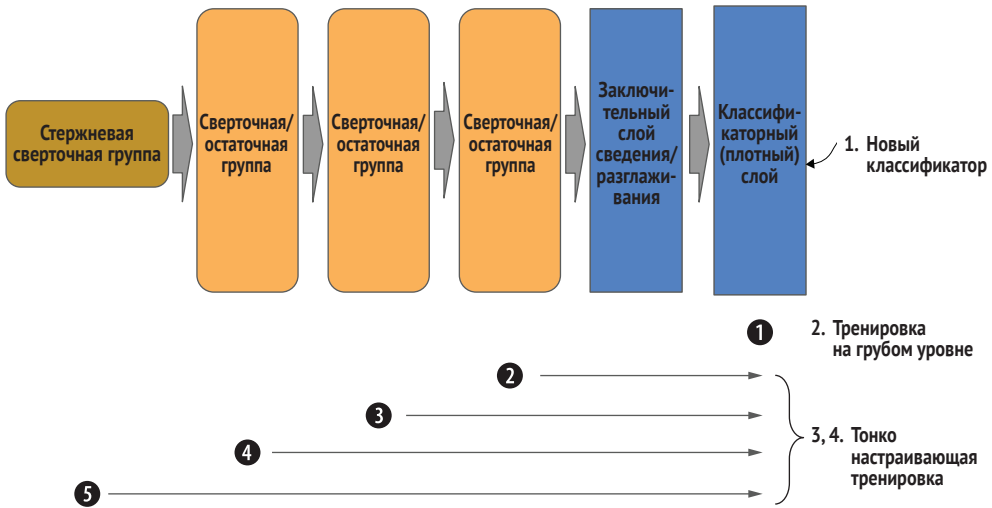


Рис. 11.6 В этом переносе обучения с несовпадающим источником и адресатом поступательно настраиваются сверточные группы

Ниже приведен пример имплементации, который демонстрирует грубую тренировку под слой нового классификатора (цикл 1), за которым следует точная настройка каждой сверточной группы (циклы 2–4) и, наконец, стержневой сверточной группы (цикл 5). Эти шаги таковы:

- 1 слои внизу модели замораживаются (`layer.trainable = False`);
- 2 классификаторный слой для 20 классов добавляется в качестве вершины модели;
- 3 классификаторный слой тренируется в течение 50 эпох:

```
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.layers import Dense
from tensorflow.keras import Model

model = ResNet50(include_top=False, pooling='avg', weights='imagenet')

for layer in model.layers:
    layer.trainable = False

output = Dense(20, activation='softmax')(model.output)

model = Model(model.input, output)
model.compile(loss='categorical_crossentropy', optimizer='adam',
              metrics=['accuracy'])

model.fit(x_data, y_data, batch_size=32, epochs=50, validation_split=0.2)
```

Замораживает веса всех преднатренированных слоев

Добавляет новый ненадтренированный классификатор

Компилирует модель для тренировки

Тренирует новый классификатор на грубом уровне

После тренировки классификатора модель тонко настраивается (циклы со 2 по 4):

- 1 пройтись по слоям снизу вверх, идентифицируя сверточную группу и конец каждой группы ResNet, что обнаруживается слоем Add();
- 2 для каждой сверточной группы создавать список каждого сверточного слоя в группе;
- 3 строить список групп в обратном порядке (`groups.insert(0, conv2d)`): сверху вниз;
- 4 пройтись по сверточным группам сверху вниз и поступательно тренировать группы и предшественников в течение пяти эпох.

Ниже приведен пример имплементации этих четырех шагов.

```

stem = None
groups = []
conv2d = []

first_conv2d = True
for layer in model.layers:
    if type(layer) == layers.convolutional.Conv2D:
        if first_conv2d == True:
            stem = layer
            first_conv2d = False
        else:
            conv2d.append(layer)
    elif type(layer) == layers.merge.Add:
        groups.insert(0, conv2d)
        conv2d = []

for i in range(1, len(groups)):
    for layer in groups[i]:
        layer.trainable = True

model.compile(loss='categorical_crossentropy', optimizer='adam',
              metrics=['accuracy'])
model.fit(x_data, y_data, batch_size=32, epochs=5)

```

В ResNet50 первый слой Conv2D является стержневым сверточным слоем

Поддерживает список в обратном порядке (самая верхняя сверточная группа находится вверху списка)

Хранит список сверточных слоев по каждой сверточной группе

Каждая сверточная группа в остаточных сетях заканчивается слоем Add()

Размораживает по одной сверточной группе за раз (сверху вниз)

Тонко настраивает (тренирует) этот слой

Наконец, стержневая сверточная группа и, следовательно, вся модель тренируются в течение дополнительных пяти эпох (цикл 5). Ниже приведен пример имплементации этого последнего шага:

```

stem.trainable = True
model.compile(loss='categorical_crossentropy', optimizer='adam',
              metrics=['accuracy'])
model.fit(x_data, y_data, batch_size=32, epochs=5, validation_split=0.2)

```

Размораживает стержневую сверточную группу

Выполняет окончательную тонкую настройку

В этом примере во время размораживания слоев для тонкой настройки модель должна быть перекомпилирована перед запуском следующего сеанса тренировки.

11.3.3 Предметно-специфичные веса

В предыдущих примерах переноса обучения мы инициализировали замороженные слои модели весами, усвоенными из набора данных ImageNet 2012. Но допустим, вы хотите использовать преднатренированные веса из какой-то конкретной предметной области, отличной от ImageNet 2012, как в нашем примере с фруктами.

Например, если вы строите модель переноса предметной области для растений, то вам могут понадобиться изображения деревьев, кустарников, цветов, сорняков, листьев, ветвей, фруктов, овощей и семян. Но нам не нужны всевозможные типы растений – достаточно усвоить существенные признаки и выделение признаков, которое можно обобщать на более конкретные и всеобъемлющие области растений. Вы также можете рассмотреть фон, на который хотите обобщать. Например, адресатной предметной областью могут быть комнатные растения, и поэтому у вас есть образцы фона домашнего интерьера, или ею может быть плодоовощная продукция, поэтому вам нужны виды на фоне полок. В источниковой области у вас должно быть определенное число экземпляров указанного фона, чтобы источниковая модель научилась отфильтровывать их из латентного пространства.

В следующем ниже примере исходного кода сначала мы тренируем архитектуру предварительно построенной ResNet50 под определенную предметную область; в данном случае фруктовую продукцию. Затем мы используем преднатренированные предметно-специфичные веса и инициализацию, чтобы натренировать еще одну модель ResNet50 в похожей предметной области, такой как овощи.

На рис. 11.7 показаны перенос предметно-специфических весов и тонкая настройка перетренировки с переносом из фруктов на похожую предметную область, овощи, следующим образом.

- 1 Инстанцировать неинициализированную модель ResNet50 без классификаторного слоя и слоя сведения, которую мы обозначаем как базовую модель.
- 2 Сохранить архитектуру базовой модели для последующего реиспользования в переносе обучения (`producemodel`).
- 3 Добавить классификатор (слои Flatten и Dense) и натренировать под конкретную (источниковую) предметную область (например, плодоовощную продукцию).
- 4 Сохранить веса натренированной модели (`produce-weights`).
- 5 Загрузить архитектуру базовой модели (`model-produce`), которая не содержит классификаторный слой.
- 6 Инициализировать архитектуру базовой модели с преднатренированными весами источниковой предметной области (`model-produce`).
- 7 Добавить классификатор новой похожей предметной области.
- 8 Натренировать модель/классификатор новой похожей предметной области.



Рис. 11.7 Перенос обучения между преднатренированной моделью предметной области, похожей на источниковую предметную область

Ниже приведен пример имплементации переноса предметно-специфичных весов фруктов путем переноса обучения в похожую предметную область овощей:

```
from tensorflow.keras.applications import ResNet50
from tensorflow.keras import Model
from tensorflow.keras.layers import Dense, Flatten
from tensorflow.keras.models import load_model

model = ResNet50(include_top=False, pooling=None, input_shape=(100, 100, 3))

model.save('produce-model')  # Сохраняет базовую модель

output = Flatten(name='bottleneck')(model.output)
output = Dense(20, activation='softmax')(output)  # Добавляет классификатор

model.save_weights('produce-weights')  # Сохраняет натренированные модельные веса

model = load_model('produce-model')
model.load_weights('produce-weights')  # Тренирует модель

output = Flatten(name='bottleneck')(model.output)
output = Dense(20, activation='softmax')(output)  # Реиспользует базовую модель и натренированные веса

model = Model(model.input, output)  # Добавляет классификатор
model.compile(loss='categorical_crossentropy', optimizer='adam',
              metrics=['accuracy'])
```

Компилирует и тренирует новую модель под новый набор данных

11.3.4 Инициализация предметно-переносимыми весами

Еще одной формой переноса обучения является передача предметно-специфичных весов для использования в качестве инициализации весов в модели, которую мы в противном случае полностью перетренировали бы. В этом случае мы пытаемся улучшить использование инициализатора, основываясь на алгоритме случайного распределения весов (например, Хе-нормального для активационных функций ReLU) по сравнению с использованием лотерейной гипотезы или численной стабилизации. Давайте еще раз посмотрим на наш пример с плодоовощной продукцией и допустим, что мы полностью натренировали модель для экземпляра набора данных, такого как фрукты. Вместо переноса весов из экземпляра полностью натренированной модели мы используем более раннюю контрольную точку, где мы достигли численной стабилизации. Мы будем реиспользовать эту более раннюю контрольную точку в качестве инициализатора с целью полной перетренировки под предметно-похожий набор данных, такой как овощи.

Передача предметно-специфичных весов является подходом с одноразовой инициализацией весов. Изначально предполагается генерировать набор инициализаций весов, который является достаточно обобщенным, чтобы тренировка модели приводила к наилучшему локальному (или глобальному) оптимуму. В идеале во время начальной тренировки веса модели будут делать следующее:

- указывать общее правильное направление схождения;
- быть сверхобобщенными, чтобы предотвращать погружение в произвольный локальный оптимум;
- использоваться в качестве инициализационных весов для одного сеанса тренировки (в качестве одноразовой инициализации), который будет сходиться на наилучшем локальном оптимуме.

На рис. 11.8 показан перенос предметной области с целью инициализации весов.

Шаги перетренировки для этой формы инициализации весов таковы:

- 1 инстанцировать модель ResNet50 случайным распределением весов (например, Ксавье или Хе-нормальным);
- 2 использовать высокоуровневую регуляризацию (l2(0.001), чтобы предотвратить подгонку к данным и низкую скорость усвоения);
- 3 выполнить несколько эпох (не показано);
- 4 сохранить веса с помощью модельного метода `save_weights()`.

```

from tensorflow.keras.regularizers import l2
model = ResNet50(include_top=False, pooling='avg', input_shape=(100, 100, 3))

```

Инстанцирует базовую модель заданной по умолчанию инициализацией весов

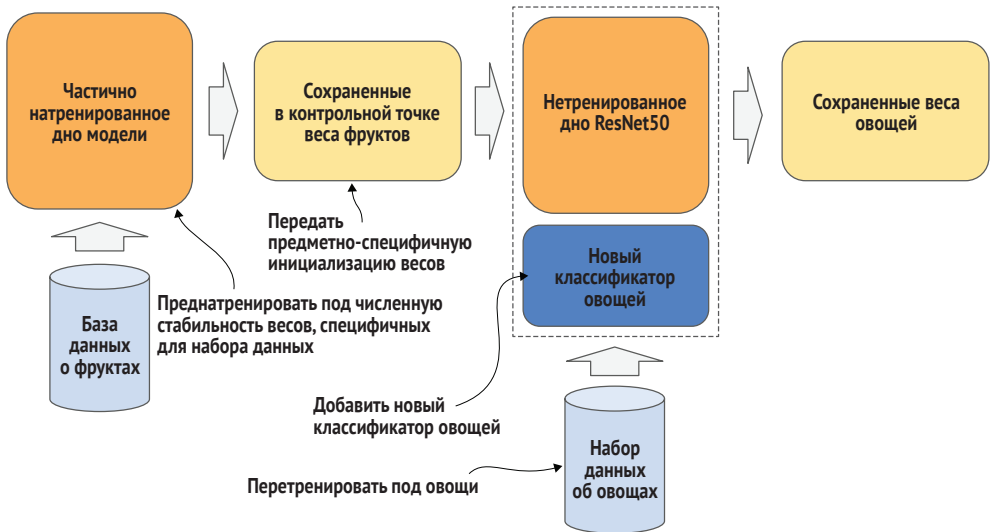
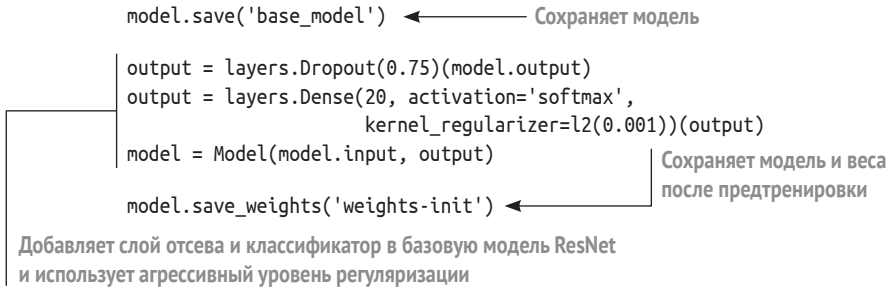



Рис. 11.8 Использование более ранних контрольных точек из похожей предметной области в качестве инициализации весов с целью полной перетренировки новой модели

В следующем ниже примере исходного кода мы начинаем полноценный сеанс тренировки с использованием сохраненных преднатренированных весов. Сначала загружаем неинициализированную базовую модель (`base_model`), которая не включает самый верхний слой. Затем загружаем поверх модели сохраненные преднатренированные веса (`weights-init`). Потом добавляем новый самый верхний слой, то есть плотный слой с 20 узлами для 20 классов. Мы строим новую модель, компилируем, а далее начинаем полную тренировку.



```
model = Model(model.input, output)
model.compile(loss='categorical_crossentropy', optimizer='adam',
              metrics=['accuracy'])
```

Компилирует и тренирует новую модель

11.3.5 Отрицательный перенос

В некоторых случаях мы обнаруживаем, что перенос обучения приводит к более низкой точности, чем тренировка с нуля: во время использования преднатренированной модели для тренировки новой модели совокупная точность во время тренировки меньше, чем была бы, если бы модель не была преднатренирована. Такая ситуация называется *отрицательным переносом*.

В подобном случае источниковая и адресатная предметные области настолько различаются, что усвоенные веса источниковой предметной области нельзя реиспользовать в адресатной предметной области. Вдобавок во время реиспользования весов модель не будет сходиться и, вполне возможно, будет расходиться. В общем случае мы обычно можем засечь отрицательный перенос в пределах 5–10 эпох.

11.4 За пределами компьютерного зрения

Методы переноса обучения, обсуждаемые в этой главе для компьютерного зрения, применимы и к моделям понимания естественного языка (NLU). За исключением отдельной терминологии, процесс полностью совпадает. В моделях понимания ЕЯ удаление вершины иногда называют *удалением головной части*.

В обоих случаях удаляется весь задачный компонент или его часть и заменяется новой задачей. То, на что вы полагаетесь, похоже на латентное пространство в компьютерном зрении; промежуточное представление содержит необходимый контекст (признаки) для усвоения новой задачи. Методы похожих задач и несовпадающих задач одинаковы для компьютерного зрения и понимания ЕЯ.

Однако то же самое не относится к структурированным данным. На самом деле перенос обучения невозможен с преднатренированными моделями между предметными областями (наборами данных). Вполне возможно усвоить задачу другого типа (например, регрессию вместо классификации) в одном и том же наборе данных, но нельзя реиспользовать усвоенные веса среди разных наборов данных, которые имеют разные признаки. Не существует концепции – по крайней мере, пока – латентного пространства, обладающего существенными признаками, которые можно реиспользовать в наборах данных с разными полями (столбцами).

Резюме

- Предварительно построенные и преднатренированные модели из репозитория моделей TF.Keras и TF Hub можно либо реиспользовать как есть для предсказаний, либо использовать для усвоения нового классификатора путем переноса обучения.
- Классификаторная группа преднатренированной модели может быть заменена обобщенной либо похожей предметной областью и перетренирована под новую область с меньшим временем тренировки и набором данных меньшего размера.
- Если в переносе обучения новая предметная область похожа на предыдущую натренированную предметную область, то замораживаются все слои, кроме нового задачного слоя, и выполняется тонко настраивающая тренировка.
- Если в переносе обучения новая предметная область отличается от предыдущей натренированной предметной области, то слои последовательно замораживаются и размораживаются по мере перетренировки, начиная с низа модели и продвигаясь к вершине.
- При переносе весов предметной области в качестве начальных весов используются веса натренированной модели и выполняется полная тренировка новой модели.

12

Распределения данных

Эта глава охватывает следующие ниже темы:

- применение статистических принципов распределений в машинном обучении;
- понимание различий между курируемыми и некурируемыми наборами данных;
- использование популяционного, выборочного и подпопуляционного распределений;
- применение концепций распределения во время тренировки модели.

Как исследователь данных и преподаватель я получаю много вопросов от инженеров-программистов о том, как повысить точность модели. Пять базовых ответов, которые я даю по поводу повышения точности модели, таковы:

- увеличивать время тренировки;
- увеличивать глубину (или ширину) модели;
- добавлять регуляризацию;
- расширять набор данных посредством обогащения данных;
- увеличивать гиперпараметрическую настройку.

Это пять наиболее вероятных мест, к которым следует обратиться, и нередко работа над тем или иным из них повышает точность модели. Но важно понимать, что лимиты точности в конечном счете заключаются в *наборе данных, используемом для тренировки модели*. И вот что мы собираемся здесь рассмотреть: нюансы наборов дан-

ных, а также то, как и почему они влияют на точность. И под нюансами я подразумеваю закономерности распределения данных.

В этой главе мы глубоко погрузимся в три типа распределения данных: популяционное, выборочное и подпопуляционное. В частности, мы рассмотрим влияние этих распределений на способность модели точно обобщать на данные в реальном мире. Вы увидите, что точность модели часто отличается от предсказаний, порождаемых тренировочным или оценочным набором данных, и такая разница именуется *перекосом в обслуживании производственных запросов и дрейфом данных*.

Во второй половине главы мы рассмотрим практический пример применения различных распределений данных к одной и той же модели во время тренировки и увидим отличающиеся исходы во время предсказательного вывода на реально существующем перекосе в обслуживании производственных запросов и дрейфе данных.

В целях понимания распределений и того, как они влияют на исходы и точность, нам нужно вернуться к базовой статистике, которую вы, вероятно, изучали в средней школе или колледже. Термин «*модель*» не был создан ни искусственным интеллектом, ни машинным обучением, ни каким-либо другим новым достижением в области вычислительных технологий. Этот термин происходит из статистики. Как инженер-программист вы привыкли кодировать алгоритм, который обычно имеет взаимосвязь «многие к одному» между входом и выходом. Обычно вход такого алгоритма имеет линейную взаимосвязь с выходом, или, другими словами, выход является детерминированным.

В статистике результат является не детерминированным, а распределением вероятностей. Давайте рассмотрим подбрасывание монеты. Невозможно написать алгоритм, который будет выдавать правильный результат орлов или решек при любом числе подбрасываний монеты, потому что он является недетерминированным. Но зато можно *смоделировать* распределение вероятностей на одном, десяти или тысячах подбрасываний монеты.

12.1 Типы распределений

Наука статистика имеет дело с алгоритмами, которые являются недетерминированными, но исходом которых является распределение вероятностей. Как и в нашем примере с подбрасыванием монеты, если я подброшу монету два раза, то исход будет недетерминированным. Вместо этого существует 50%-ная вероятность того, что одно подбрасывание будет орлом, а другое – решкой, и 25%-ная вероятность того, что оба подбрасывания будут орлами и соответственно оба подбрасывания – решками. Такие алгоритмы называются *моделями*, и они моделируют поведение, которое дает результат (или ис-

ход) предсказания на распределении вероятностей. Это действительно похоже на статистику, верно?

В данном разделе мы рассмотрим три распределения, наиболее часто используемых в моделировании машинного обучения: популяционное, выборочное и подпопуляционное. Здесь наша цель состоит в том, чтобы увидеть, как каждое распределение влияет на тренировку модели глубокого обучения, в особенности на ее точность.

Приход глубокого обучения с использованием нейронных сетей для разработки моделей относится к области искусственного интеллекта. В последние годы две отдельные области – статистическое моделирование и глубокое обучение – слились воедино, и теперь мы относим их к категории машинного обучения. Но независимо от того, занимаетесь ли вы тем, что я называю классическим машинным обучением (статистикой) либо глубоким обучением с помощью нейронных сетей, ограничение в том, что вы можете моделировать или усваивать, сводится к набору данных.

Для того чтобы посмотреть на эти три распределения, мы будем использовать набор данных MNIST (<https://keras.io/datasets/>). Этот набор данных достаточно мал, что позволяет его использовать для демонстрации каждой из этих концепций, а также предоставить вам примеры исходного кода, которые вы сможете воспроизвести и использовать, чтобы увидеть своими глазами, почему (и как) данные являются ограничением.

12.1.1 *Популяционное распределение*

Когда вы строите модель и оказывается, что она не обобщает так, как от нее ожидается «в дикой природе» (в производстве), одна из причин обычно заключается в том, что вы не поняли популяционное распределение того, что вы моделируете.

Допустим, вы строили модель для предсказания размера обуви взрослого мужчины в Соединенных Штатах на основе физических характеристик (роста, цвета волос и т. д.). Популяционное распределение в этой модели будет включать всех взрослых мужчин в Соединенных Штатах. Здесь важно подчеркнуть, что *всех*. Когда мы говорим о *популяционном распределении*, то имеем в виду каждый отдельный пример в популяции – всю популяцию целиком. С популяционным распределением мы знаем полное распределение размеров обуви и соответствующих признаков (роста, цвета волос и т. д.).

Проблема, разумеется, в том, что у вас не будет данных по всем взрослым мужчинам в Соединенных Штатах. Вместо этого у вас будет подмножество данных: мы берем пакеты данных в случайном порядке (которые называем *случайной выборкой*), чтобы определять распределение внутри пакета, которое, как вы надеетесь, близко соответствует распределению совокупной популяции.

На рис. 12.1 показана случайная выборка внутри популяционного распределения. Внешний круг с надписью «Популяция» представля-

ет все примеры в популяции, например в нашем примере размеры обуви всех взрослых мужчин в Соединенных Штатах. Внутренний круг, помеченный как «Случайная выборка», представляет случайно выбранное подмножество примеров, таких как случайно выбранное число взрослых мужчин в Соединенных Штатах. В случае популяционного распределения мы знаем такие вещи, как точный размер (число взрослых мужчин), среднее значение (средний размер обуви) и стандартное отклонение (процент разных размеров). В статистике они называются *параметрами* популяции, то есть детерминированного распределения. Допустив, что у нас нет популяционного распределения, мы хотим использовать случайную выборку, чтобы оценить параметры. Такое оценивание называется *статистикой*. Чем больше и случайнее выборка, тем вероятнее, что наша оценка будет ближе к параметрам.

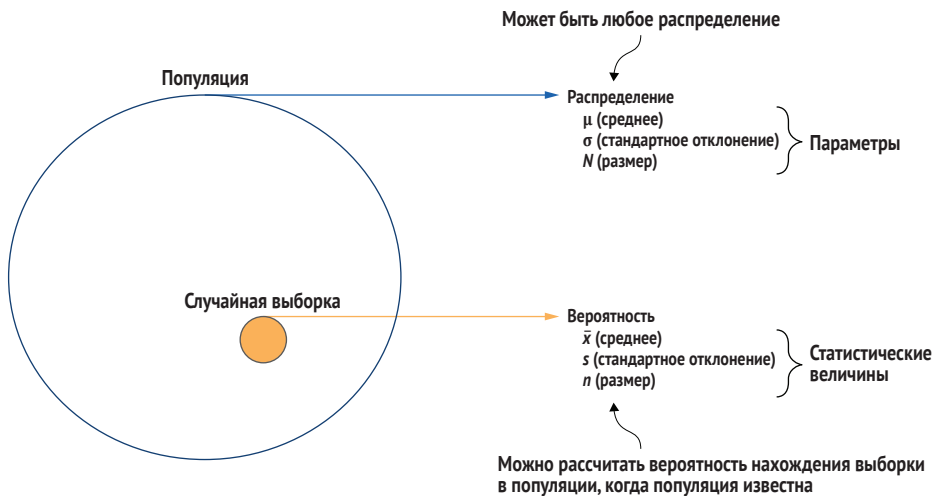


Рис. 12.1 Популяционное распределение и случайная выборка внутри популяции

12.1.2 Выборочное распределение

Цель выборочного распределения состоит в том, чтобы иметь достаточное число случайных выборок из популяции, дабы распределения внутри этих выборок можно было использовать коллективно для предсказания распределения внутри популяции в целом, и, таким образом, можно было обобщать модель на популяцию. Здесь ключевым словом является «*предсказывать*», имея в виду, что мы определяем вероятностное распределение из выборок вместо детерминированного распределения из популяции.

Давайте возьмем наш случай с размером обуви. Если бы у нас был только один пример, то мы, вероятно, не смогли бы адекватно смоделировать параметры распределения. Но если бы у нас была тысяча примеров, то, возможно, мы смогли бы существенно расширить

наши возможности по моделированию параметров. Но подождите, а что, если эти тысячи на самом деле не были случайными – скажем, они были собраны из покупок в магазине профессиональной спортивной обуви. Указанные примеры, скорее всего, будут смещены к определенным характеристикам (признакам) неслучайных примеров. И поэтому примеры в выборочном распределении должны непременно отбираться случайно.

На рис. 12.2 показано выборочное распределение популяции. Выборочное распределение состоит из набора примеров, которые были отобраны случайно и обычно имеют одинаковый размер. Например, мы могли бы нанять разные социологические компании для сбора данных о размерах обуви, причем каждая из них использовала бы свои собственные критерии отбора. Каждая компания собирает данные на сотне случайных примеров, основываясь на своих критериях отбора.

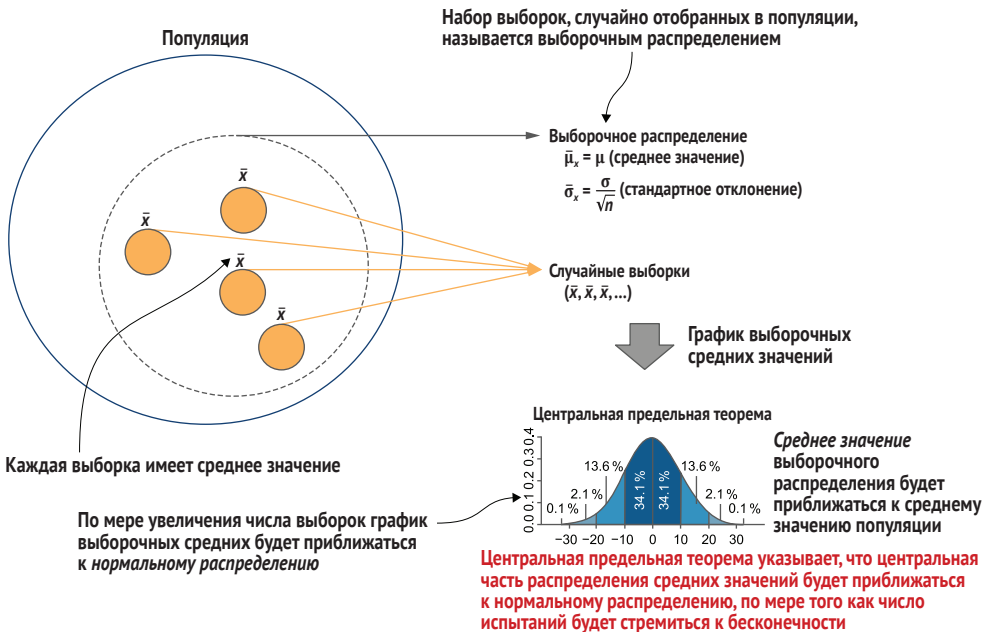


Рис. 12.2 Выборочное распределение, которое предсказывает параметры популяционного распределения

Мы можем предположить, что каждая из этих отдельных случайных выборок является слабым предсказателем параметров популяции. Вместо этого мы трактуем их как ансамбль. Например, если мы возьмем среднее значение каждой случайной выборки, учитывая достаточное число случайных выборок достаточного размера, то сможем точнее предсказывать среднее значение популяции.

В общем случае набор данных, который вы используете, чтобы тренировать модель, является выборочным распределением, и чем больше размер выборки и чем случайнее примеры, тем вероятнее, что ваша модель будет обобщать на параметры популяции.

12.1.3 Подпопуляционное распределение

Следует понимать, что независимо от того, насколько велик и полон ваш набор данных, скорее всего, он является выборочным распределением подпопуляции, а не всей популяции. *Подпопуляция* – это подмножество популяции, которое определяется множеством характеристик и которое не будет иметь такого же распределения вероятностей, что и популяция. Как и в нашем предыдущем примере с обувью для взрослых мужчин, давайте допустим, что все наши выборки взяты из сети магазинов, специализирующихся на продаже спортивной обуви профессиональным спортсменам. При наличии достаточного числа выборок мы сможем разработать выборочное распределение, которое будет представительным и, следовательно, предсказательным для подпопуляции профессиональных спортсменов, но вряд ли оно будет весомо представлять всю популяцию.

Это не то же самое, что и смещение, при условии что мы намерены моделировать именно эту подпопуляцию, а не популяцию в целом. Смещение возникает, когда мы черпаем из пакетов случайных выборок, но независимо от того, из скольких пакетов мы черпаем, соответствующее выборочное распределение не будет представлять весомерно популяцию, которую мы моделируем, – потому что мы черпали случайные выборки из подпопуляции. На рис. 12.3 показано подпопуляционное распределение.

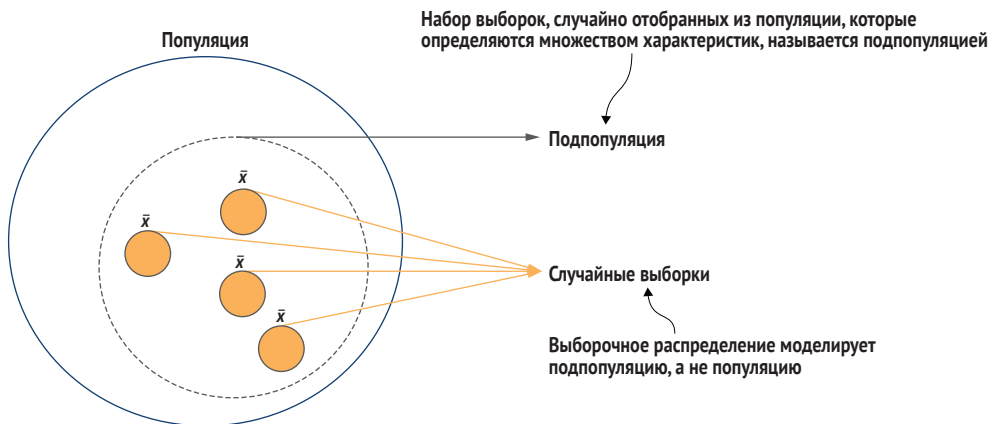


Рис. 12.3 Подпопуляционное распределение

12.2 Вне распространения

Давайте допустим, что вы натренировали модель и развернули ее на наборе данных, но она не обобщает на то, что она действительно видит в производстве, а также на ваши оценочные данные. Эта модель, возможно, видит другое распределение примеров, отличное от того, на котором модель была натренирована. Мы называем такую ситуацию расположением *вне распределения*, т. н. *перекосом в обслуживании производственных запросов*. Другими словами, ваша модель была натренирована на подпопуляционном распределении, которое отличается от того, что видит развернутая модель.

В этом разделе мы будем использовать набор данных MNIST, чтобы продемонстрировать то, как обнаруживать популяции вне распределения при развертывании модели. Затем мы разведем подходы к улучшению возможностей модели по обобщению на популяцию, находящуюся вне распределения. Мы обсудили набор данных MNIST впервые в главе 2. Начнем с краткого освежения памяти об этом наборе данных.

12.2.1 Курируемый набор данных MNIST

MNIST – это набор данных из 70 000 изображений рукописных цифр, которые сбалансированы пропорционально по каждой цифре. С этим набором данных очень легко натренировать модель, чтобы получить почти 100%-ную точность на наборе данных (и, следовательно, в машинном обучении он является примером из разряда «привет, мир»). Но почти все применения натренированной модели «в дикой природе» откажут – потому что распределение изображений в MNIST является подпопуляционным.

MNIST – это курируемый набор данных. Куратор данных отобрал образцы для включения, характеристики которых соответствуют некоторому определению. Другими словами, курируемый набор данных достаточно весомо представляет подпопуляцию, чтобы можно было моделировать параметры этой подпопуляции, но в иных случаях, возможно, набор не будет представлять весомо всю популяцию целиком (например, все цифры).

В случае MNIST каждый образец является изображением размером 28×28 пикселей, причем изображение цифры центрировано посередине. Цифра имеет белый цвет, серый фон, а вокруг цифры имеется дополнение не менее 4 пикселями. На рис. 12.4 показана компоновка изображения MNIST. Этот экземпляр цифры 7 был отобран из набора данных произвольно в случайном порядке и используется только для примера.

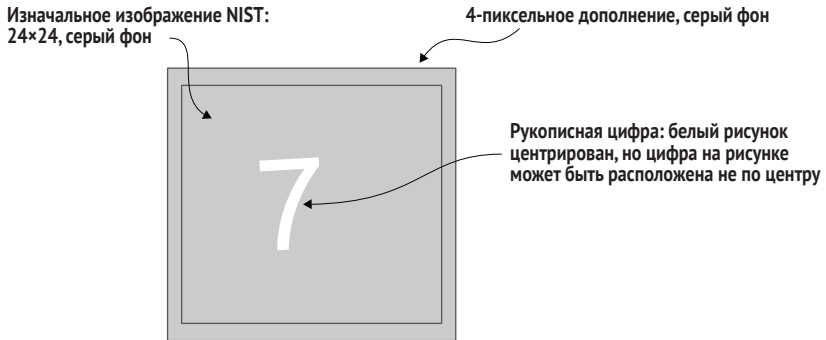


Рис. 12.4 Компоновка изображения MNIST

12.2.2 Настройка среды

Сначала давайте займемся тем, что я называю *организующими мероприятиями*. Ниже приведен фрагмент исходного кода, который мы будем использовать во всех наших примерах. В него входит импорт API TF.Keras для конструирования и тренировки моделей, различные библиотеки Python, которые мы будем применять, и, наконец, загрузка набора данных MNIST, предварительно встроенного в API TF.Keras:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Flatten, Dense, Activation, ReLU,
from tensorflow.keras.layers import MaxPooling2D, Conv2D, Dropout

import numpy as np
import random
import cv2

from tensorflow.keras.datasets import mnist
(x_train, y_train), (x_test, y_test) = mnist.load_data()
```

Получает встроенный набор данных MNIST

Набор данных из Keras представлен в генерическом формате, поэтому нам необходимо выполнить некоторую начальную подготовку данных, чтобы использовать его для тренировки глубокой или сверточной нейросети. Эта подготовка предусматривает следующее:

- пиксельные данные (`x_train` и `x_test`) содержат изначальные значения с типом INT8 (от 0 до 255). Мы нормализуем пиксельные данные в интервал между 0 и 1 с типом FLOAT32;
- матрицы с данными изображений имеют форму *Высота×Ширина* ($H \times W$). Keras ожидает тензоры в форме *Высота×Ширина×Канал*. Эти изображения записаны в оттенках серого, поэтому мы реформируем тренировочные и тестовые данные в форму ($H \times W \times 1$).

Мы также отложим копию тестовых и тренировочных данных до их подготовки (что обсудим в разделе 12.2.3).

```
x_test_copy = x_test      | Откладывает копию изначальных
x_train_copy = x_train    | тренировочных и тестовых данных

x_train = (x_train / 255.0).astype(np.float32) | Нормализует пиксельные данные
x_test = (x_test / 255.0).astype(np.float32)   | и приводит их к типу 32-битного
                                                | числа с плавающей точкой

x_train = x_train.reshape(-1, 28, 28, 1) | Реформирует в форму H×W×1
x_test = x_test.reshape(-1, 28, 28, 1)   | для API модели TF.Keras

print("x_train", x_train.shape, "x_test", x_test.shape)
print("y_train", y_train.shape, "y_test", y_test.shape)
```

12.2.3 Серьезное испытание («дикой природой»)

В дополнение к случайному выбору тестовых данных (т. н. *отложенного набора*) из этого набора данных мы также создадим еще два набора тестовых данных в качестве примеров того, что натренированная модель может увидеть в дикой природе. Эти два дополнительных набора данных, именуемых *инвертированным набором* и *сдвинутым набором*, будут содержать примеры, которые не представлены тренировочными данными. Другими словами, изначальный набор данных MNIST является одной подпопуляцией популяции цифр, а два наших новых набора данных являются разными подпопуляциями цифр. Инвертированный и сдвинутый наборы имеют распределение, отличное от набора данных MNIST, и поэтому мы называем их как находящиеся вне распределения относительно набора данных MNIST.

Мы будем использовать эти два дополнительных тестовых набора данных, чтобы продемонстрировать то, как модель будет отказывать, и отыскивать способы, которыми мы могли бы модифицировать тренировку и набор данных, чтобы преодолеть эту ситуацию и ограничения. Что же, собственно говоря, представляет собой каждый набор?

- *Инвертированный набор* – пиксельные данные инвертированы таким образом, что изображения теперь являются серыми цифрами на белом фоне.
- *Сдвинутый набор* – изображения сдвинуты на 4 пиксела вправо и, следовательно, больше не центрированы. Поскольку дополнение составляет не менее 4 пикселей, ни одна из цифр не будет обрезана.

На рис. 12.5 приведен пример одного тестового изображения из изначальных тестовых данных, инвертированных тестовых данных и сдвинутых тестовых данных.

В приведенном ниже исходном коде мы создаем два дополнительных тестовых набора данных из копии изначального тестового набора данных:


```

x_test_invert = np.invert(x_test_copy)
x_test_invert = (x_test_invert / 255.0).astype(np.float32)

x_test_shift = np.roll(x_test_copy, 4)
x_test_shift = (x_test_shift / 255.0).astype(np.float32)

x_test_invert = x_test_invert.reshape(-1, 28, 28, 1)
x_test_shift = x_test_shift.reshape(-1, 28, 28, 1)

```

Инвертированные данные
«из дикой природы»

Сдвинутые данные
«из дикой природы»



Рис. 12.5 Изначальный пример и примеры вне распределения из дикой природы

12.2.4 Тренировка в качестве глубокой нейросети

Мы начнем с того, что натренируем модель, основываясь на подпопуляции MNIST «как есть», сравним точность на отложенном наборе, относящемся к той же самой подпопуляции, и, наконец, протестируем и сравним их с данными вне распределения.

Набор данных MNIST настолько прост, что мы можем построить классификатор с точностью более 97 % с помощью глубокой нейросети. Следующий ниже пример исходного кода является функцией, предназначенной для строительства простых глубоких нейросетей, которая содержит следующее:

- параметр `nodes` является списком, задающим число узлов в расчете на слой;
- на вход в глубокую нейросеть подаются изображения в форме $28 \times 28 \times 1$;
- подаваемые на вход данные разглаживаются в 1-мерный вектор длиной 784;
- после каждого слоя есть необязательный отсев (для регуляризации);
- последний плотный слой из 10 узлов с активационной функцией `softmax` является классификатором.

Рисунок 12.6 иллюстрирует конфигурируемую архитектуру глубокой нейросети для этого примера.

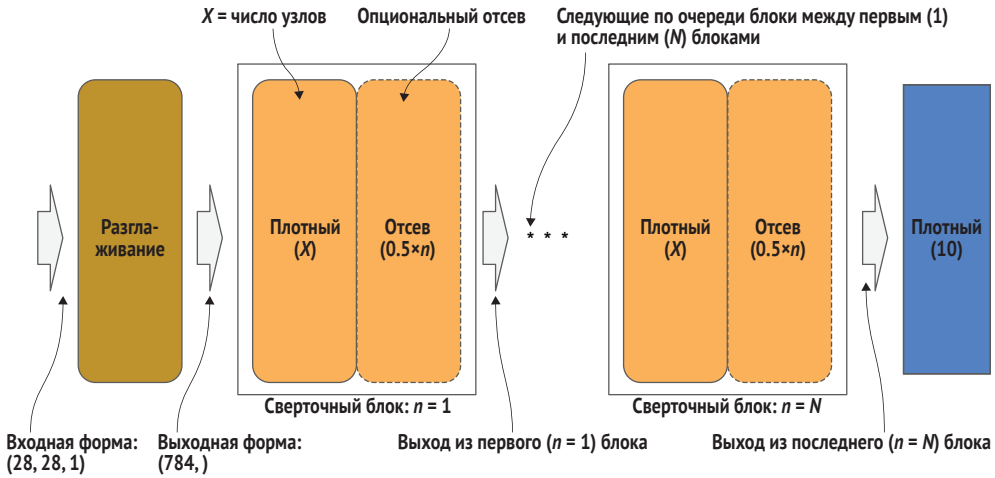


Рис. 12.6 Конфигурируемая архитектура глубокой нейросети для модели MNIST

```
def DNN(nodes, dropout=False):
    model = Sequential()
    model.add(Flatten(input_shape=(28, 28, 1)))
    for n_nodes in nodes:
        model.add(Dense(n_nodes))
        model.add(ReLU())
        if dropout:
            model.add(Dropout(0.5))
            dropout /= 2.0
    model.add(Dense(10))
    model.add(Activation('softmax'))

    model.compile(optimizer='adam', loss='sparse_categorical_crossentropy',
                  metrics=['accuracy'])
    model.summary()
    return model
```

Функция для строительства простых глубоких нейросетей

Компилирует глубокую нейросеть для мультиклассового классификатора

Для нашего первого теста мы выполним тренировку одного слоя (исключая выходной слой) из 512 узлов на наборе данных. На рис. 12.7 изображена соответствующая архитектура.

Ниже приведен исходный код для строительства, тренировки и оценивания модели для первого теста:

```
model = DNN([512])
model.fit(x_train, y_train, epochs=10, batch_size=32, shuffle=True,
         verbose=2)
score = model.evaluate(x_test, y_test, verbose=1)
print("test", score)
```

Тренирует модель MNIST

Оценивает натренированную модель

Результат на выходе из метода `summary()` будет выглядеть следующим образом:

Layer (type)	Output Shape	Param #
flatten_1 (Flatten)	(None, 784)	0
dense_1 (Dense)	(None, 512)	401920
re_lu_1 (ReLU)	(None, 512)	0
dense_2 (Dense)	(None, 10)	5130
activation_1 (Activation)	(None, 10)	0
Total params: 407,050		




Рис. 12.7 Однослойная 512-узловая глубокая нейросеть для нашей первой модели MNIST, которую мы тренируем

Число тренируемых параметров является мерой сложности нашей модели, которое составляет 408 000 параметров. Мы тренируем ее в общей сложности в течение 10 эпох (подаем в модель все тренировочные данные целиком 10 раз). Ниже приведены результаты тренировки. Тренировочная точность быстро достигает 99 %+, а точность на тестовых (отложенных) данных составляет почти 98 %.

Epoch 1/10

2019-02-08 12:14:59.065963: I

tensorflow/core/platform/cpu_feature_guard.cc:141] Your CPU supports instructions that this TensorFlow binary was not compiled to use: AVX2 AVX512F FMA

- 5s - loss: 0.2007 - acc: 0.9409

Epoch 2/10

- 5s - loss: 0.0897 - acc: 0.9743

Epoch 3/10

```

- 5s - loss: 0.0651 - acc: 0.9817
Epoch 4/10
- 5s - loss: 0.0517 - acc: 0.9853
Epoch 5/10
- 5s - loss: 0.0419 - acc: 0.9887
Epoch 6/10
- 5s - loss: 0.0341 - acc: 0.9913
Epoch 7/10
- 5s - loss: 0.0273 - acc: 0.9928
Epoch 8/10
- 5s - loss: 0.0236 - acc: 0.9939
Epoch 9/10
- 5s - loss: 0.0188 - acc: 0.9953
Epoch 10/10
- 5s - loss: 0.0163 - acc: 0.9961
10000/10000 [=====] - 0s 21us/step

test [0.11250439590732676, 0.9791]

```

Пока что все выглядит хорошо. Теперь давайте попробуем модель на инвертированном и сдвинутом тестовых наборах данных:

```

score = model.evaluate(x_test_invert, y_test, verbose=1)
print("inverted", score)
score = model.evaluate(x_test_shift, y_test, verbose=1)
print("shifted", score)

```

Оценивает модель на инвертированном
наборе данных вне распределения

Оценивает модель на сдвинутом наборе
данных вне распределения

Ниже приведен результат на выходе. Точность на инвертированном наборе данных составляет всего 2 %, а на сдвинутом наборе данных она выше, но только 41 %:

```

inverted [15.660332287597656, 0.0206]
shifted [7.46930496673584, 0.4107]

```

Что случилось? В случае инвертированного набора данных похоже, что наша модель усвоила серый фон и белизну цифры как часть распознавания цифр. Отсюда, когда мы инвертировали данные, модель полностью отказала в их классифицировании.

В случае сдвинутого набора данных плотный слой не сохраняет пространственные взаимосвязи между пикселями. Каждый пиксел является уникальным признаком. Отсюда было достаточно сдвига даже на несколько пикселей, чтобы резко снизить точность.

Поэтому в целях повышения точности мы могли бы попытаться увеличить число узлов во входном слое – чем больше узлов, тем лучше усвоение. Давайте повторим тот же тест с 1024 узлами. На рис. 12.8 изображена соответствующая архитектура.

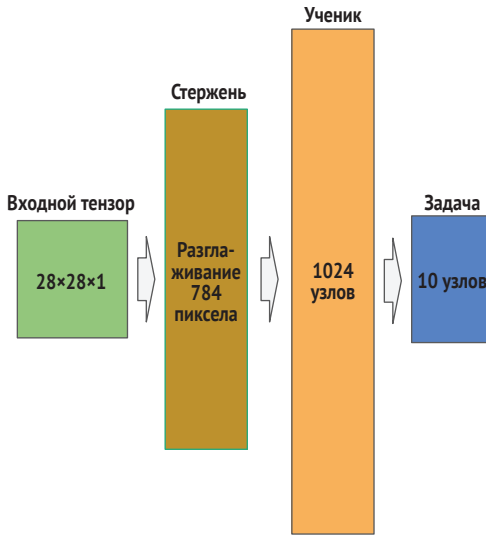


Рис. 12.8 Более широкая однослойная 1024-узловая глубокая нейросеть для нашей второй модели MNIST, которую мы тренируем

Ниже приведен исходный код для строительства, тренировки и оценивания модели для второго теста:

```
model = DNN([1024])  ← Число узлов удвоено (расширено)
model.fit(x_train, y_train, epochs=10, batch_size=32, shuffle=True,
         verbose=2)
score = model.evaluate(x_test, y_test, verbose=1)
print("test", score)
```

Результат на выходе из метода `model.summary()` выглядит следующим образом:

Layer (type)	Output Shape	Param #
flatten_2 (Flatten)	(None, 784)	0
dense_3 (Dense)	(None, 1024)	803840
re_lu_2 (ReLU)	(None, 1024)	0
dense_4 (Dense)	(None, 10)	10250
activation_2 (Activation)	(None, 10)	0
Total params: 814,090		
Trainable params: 814,090		

Хорошо видно, что, удвоив число узлов во входном слое, мы удваиваем вычислительную сложность (число тренируемых параметров).

Давайте посмотрим, повысит ли это точность на наших альтернативных тестовых данных.

А вот и нет. Мы видим незначительное увеличение на инвертированном наборе данных примерно до 5 %, но оно настолько низкое, что, вероятно, является просто шумом, а точность на сдвинутом наборе данных примерно такая же – 40 %. Таким образом, увеличение числа узлов во входном слое (расширение) не помогло ни отфильтровать (не усваивать) фон и белизну цифр, ни усвоить пространственные взаимосвязи:

```
inverted [15.157325344848633, 0.0489]
shifted [7.736222146606445, 0.4038]
```

Мы могли бы попробовать еще один подход, а именно увеличить число слоев (углубление). На этот раз давайте создадим глубокую нейросеть с двумя слоями по 512 узлов каждый. На рис. 12.9 изображена архитектура нашей модели.




Рис. 12.9 Более глубокая двухслойная глубокая нейросеть (512 + 512 узлов) для нашей третьей модели MNIST, которую мы тренируем

Ниже приведен исходный код строительства, тренировки и оценивания модели для третьего теста:

```
model = DNN([512, 512]) ← Увеличивает число слоев (углубляет)
model.fit(x_train, y_train, epochs=10, batch_size=32, shuffle=True,
         verbose=2)
score = model.evaluate(x_test, y_test, verbose=1)
print("test", score)
```

Окончательный результат на выходе из метода `model.summary()` таков:

```
Total params: 669,706
Trainable params: 669,706
```

Давайте посмотрим, повысит ли это точность на наших альтернативных тестовых данных:

inverted [14.464950880432129, 0.1025]

shifted [8.786513813018798, 0.3887]

Мы видим еще одно небольшое увеличение на сдвинутом наборе данных до 10 %. Но действительно ли она улучшилась? У нас 10 классов (цифр). Если бы мы делали случайные догадки, то были бы правы в 10 % случаев. Это все еще чисто случайный результат – здесь ничего не усвоено. Похоже, добавление слоев не помогло и в усвоении пространственных взаимосвязей.

Еще один подход состоял бы в добавлении некоторой регуляризации, чтобы предотвратить переподргонку модели к тренировочным данным и сделать ее более обобщенной. Мы будем использовать ту же двухслойную глубокую нейросеть из 512 узлов в расчете на слой и добавим 50%-ный отсев после первого слоя и 25%-ный отсев после второго слоя. Раньше на практике было принято использовать более высокий отсев в первом слое, который усваивает грубые признаки, и использовать меньший отсев в последующих слоях, которые усваивают более детализированные признаки. На рис. 12.10 показана архитектура модели.




Рис. 12.10 Глубокая нейросеть с отсевом, добавленным, чтобы улучшить обобщение

Ниже приведен исходный код для строительства, тренировки и оценивания модели для четвертого теста:

```

model = DNN([512, 512], True) ← Добавляет отсев для регуляризации
model.fit(x_train, y_train, epochs=10, batch_size=32, shuffle=True,
         verbose=2)
score = model.evaluate(x_test, y_test, verbose=1)
print("test", score)
  
```

Давайте посмотрим, повысит ли это точность на наших альтернативных тестовых данных:

```
inverted [15.862942279052735, 0.0144]
shifted [8.341207506561279, 0.3965]
```

Снова нет. Никаких улучшений. Таким образом, расширение слоя, углубление слоев и регуляризация не помогли в тренировке модели распознавать цифры в тестовых наборах данных вне распределения. Возможно, проблема состоит в том, что глубокая нейросеть как тип модельной архитектуры просто не подходит для обобщения на данные вне распределения. Далее мы попробуем сверточную нейросеть и посмотрим, что произойдет.

12.2.5 Тренировка в качестве сверточной нейросети

Ладно, теперь давайте проверим точность на трех наборах данных в сверточной нейронной сети. С помощью сверточных слоев мы должны, по крайней мере, усваивать пространственные взаимосвязи. Возможно, сверточные слои будут отфильтровывать фон, а также белизну цифр.

Следующий ниже исходный код строит наши сверточные нейросети следующим образом:

- параметр `filters` является списком, задающим число фильтров в расчете на свертку;
- на вход в сверточную нейросеть подаются изображения в форме $28 \times 28 \times 1$;
- максимальное сведение сокращает размеры карт признаков на 75 % после каждой свертки;
- отсев (регуляризация) в размере 25 % происходит после каждого слоя свертки / максимального сведения;
- последний плотный слой из 10 узлов с активационной функцией `softmax` является классификатором.

```
def CNN(filters):
    model = Sequential()
    first = True
    for n_filters in filters:
        if first:
            model.add(Conv2D(n_filters, (3, 3), strides=1,
                             input_shape=(28, 28, 1)))
        else:
            model.add(Conv2D(n_filters, (3, 3), strides=1))
    model.add(ReLU())
    model.add(MaxPooling2D((2, 2), strides=2))
    model.add(Dropout(0.25))
    model.add(Flatten())
    model.add(Dense(10))
    model.add(Activation('softmax'))
```

← Функция для строительства простых сверточных нейросетей


```

model.compile(optimizer='adam', loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
model.summary()
return model

```

Компилирует сверточную нейросеть для мультиклассового классификатора

Давайте начнем со сверточной нейросети с одним сверточным слоем из 16 фильтров. На рис. 12.11 показана архитектура модели.




Рис. 12.11 Однослойная сверточная нейросеть для тренировки нашей модели MNIST

Ниже приведен исходный код для строительства, тренировки и оценивания модели для первого теста со сверточной нейросетью:

```

model = CNN([16])
model.fit(x_train, y_train, epochs=10, batch_size=32, shuffle=True,
        verbose=2)
score = model.evaluate(x_test, y_test, verbose=1)
print("test", score)

```

Строит сверточную нейросеть с 16 фильтрами

Результат на выходе из метода `model.summary()` выглядит следующим образом:

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 26, 26, 16)	160
re_lu_1 (ReLU)	(None, 26, 26, 16)	0
max_pooling2d_1 (MaxPooling2D)	(None, 13, 13, 16)	0
dropout_1 (Dropout)	(None, 13, 13, 16)	0
flatten_1 (Flatten)	(None, 2704)	0
dense_1 (Dense)	(None, 10)	27050
activation_1 (Activation)	(None, 10)	0

```
=====
Total params: 27,210
Trainable params: 27,210
```

Ниже приведен результат нашей тренировки сверточной нейросети:

```
test [0.05741905354047194, 0.9809]
```

Как вы видите, со сверточной нейросетью можно получить сопоставимую точность (98 %) на тестовых данных с гораздо меньшим числом тренируемых параметров (27 000 против более чем 400 000).

Давайте посмотрим, повысит ли это точность на наших альтернативных тестовых данных:

```
inverted [2.1893138484954835, 0.5302]
shifted [2.231996842956543, 0.5682]
```

Да, повысило, составив ощутимую разницу. Мы перешли от предыдущего максимума точности в 10 % на инвертированном наборе данных к точности в 50 %. Таким образом, похоже, что сверточные слои помогают отфильтровывать (а не усваивать) фон или белизну цифр.

Но это все еще слишком низкая точность. На сдвинутом наборе данных мы увеличили ее до 57 %. Это все еще ниже нашей цели, но мы также видим, что теперь сверточные слои усваивают пространственные взаимосвязи. Итак, чему мы здесь научились? Тому, что если у вас неправильная модельная архитектура, не важно, насколько глубже или шире делать модель или сколько регуляризации добавлять; модель не будет обобщать на тестовые данные вне распределения. Мы также узнали, что сверточная нейросеть не только лучше обобщает, но и намного эффективнее в параметрах, и в нашем первом тесте мы сделали это лишь с помощью стержня и без ученического компонента.

Если один сверточный слой улучшил ситуацию, то давайте посмотрим, насколько лучше у нас получится с двумя сверточными слоями. Мы будем использовать два слоя: первый с 16 фильтрами и второй с 32 фильтрами. На практике традиционно принято удваивать число фильтров по мере углубления в сверточную нейросеть. На рис. 12.12 изображена архитектура нашей модели.

Ниже приведен исходный код для строительства, тренировки и оценивания модели для второго теста со сверточной нейросетью:

```
model = CNN([16, 32])  ← Строит двухслойную сверточную нейросеть
model.fit(x_train, y_train, epochs=10, batch_size=32, shuffle=True,
         verbose=2)
score = model.evaluate(x_test, y_test, verbose=1)
print("test", score)
```




Рис. 12.12 Более глубокая двухслойная сверточная нейросеть для нашей тренировки модели MNIST

Ниже приведен результат нашей тренировки сверточной нейросети:

test [0.03628469691830687, 0.9882]

Опять же, мы получаем сопоставимую точность с небольшим улучшением на тестовых данных до ~ 99 %. Давайте посмотрим, улучшит ли добавление сверточных слоев точность на наших альтернативных тестовых данных:

inverted [1.2761547603607177, 0.6332]

shifted [0.6951200264453888, 0.7679]

Мы действительно видим некоторое инкрементное улучшение. Точность на нашем инвертированном наборе данных выросла до 63 %. И значит, она учится лучше отфильтровывать фон и белизну цифр, но она все еще не дотягивает. Наш тест со сдвинутым набором данных подскочил до 76 %. Таким образом, вы видите, как сверточные слои усваивают пространственные взаимосвязи в цифрах вместо положения на изображении (по сравнению с глубокой нейросетью).

12.2.6 Обогащение изображений

Наконец, давайте воспользуемся обогащением (аугментацией) изображений, чтобы попытаться улучшить модель в части обобщения на альтернативные тестовые данные, находящиеся вне распределения. Напомним, что *обогащение изображений* – это процесс создания новых образцов из существующих образцов путем внесения малых модификаций. Эти модификации не изменяют то, как изображение будет классифицироваться, и человеческий глаз по-прежнему будет распознавать изображение как относящееся к этому классу.

На рис. 12.13 показан пример обогащения изображения, в котором изображение кошки было случайным образом повернуто, а затем об-

резано, а его размер изменен на размер изначальной формы. Изображение по-прежнему узнаваемо человеческим глазом как кошка.

В дополнение к добавлению в тренировочный набор большего числа образцов определенные типы обогащения способны помогать в обобщении модели с целью точного классифицирования изображений за пределами тестового (отложенного) набора данных, на котором в иных ситуациях она отказывала бы.

Как мы увидели на нашей сверточной нейросети, у нас по-прежнему была недостаточная точность на сдвинутых изображениях; отсюда наша модель не полностью усваивала пространственные взаимосвязи цифр, отделенных от расположения и фона на изображении. Можно было бы добавить больше фильтров и сверточных слоев в попытке повысить точность на сдвинутых изображениях. Это сделало бы модель сложнее в вычислительном отношении и удлинило бы ее тренировку, а также увеличило бы объем памяти и задержку после ее развертывания для выполнения предсказаний (предсказательного вывода).



Рис. 12.13 Конвейер обогащения изображений для генерирования примеров со случайно отобранными трансляциями

В качестве альтернативы мы собираемся улучшить модель за счет обогащения изображений путем случайного сдвига изображения влево или вправо на 20 %. Поскольку ширина наших изображений составляет 28 пикселей, 20 % будет означать, что изображение будет смещено максимум на 6 пикселей в любом направлении. У нас есть минимум 4-пиксельная граница, поэтому обрезки цифр практически не будет.

Для обогащения изображений мы будем использовать библиотечный класс `ImageDataGenerator` из `TF.Keras`. В следующем ниже примере исходного кода мы делаем вот что:

- создаем ту же самую сверточную нейросетевую модель, что и раньше;
- инстанцируем генераторный объект `ImageDataGenerator`, параметр `width_shift_range=0.2` которого будет обогащать набор

данных во время тренировки за счет случайного сдвига изображений $\pm 20\%$;

- вызываем метод `fit_generator()` для тренировки модели с использованием нашего генератора обогащения изображений с существующими тренировочными данными;
- указываем число шагов на эпоху (`steps_per_epoch`) в генераторе как число тренировочных образцов, деленное на размер пакета; в противном случае генератор застрянет в бесконечном цикле в первую эпоху:

```
from tensorflow.keras.preprocessing.image import ImageDataGenerator
model = CNN([16, 32])
datagen = ImageDataGenerator(width_shift_range=0.2)
model.fit_generator(datagen.flow(x_train, y_train, batch_size=32),
                    steps_per_epoch= 60000 // 32 , epochs=10),
score = model.evaluate(x_test, y_test, verbose=1)
print("test", score)
```

Инстанцирует генератор для случайного
сдвига изображений на $\pm 20\%$

Тренирует модель,
используя обогащение изображений

Ниже приведен результат нашей тренировки сверточной нейросети:

```
test [0.046405045648082156, 0.986]
```

Давайте посмотрим, повысит ли это точность на тестовых данных вне распределения:

```
inverted [4.463096208190918, 0.2338]
shifted [0.06386796866590157, 0.9796]
```

Блеск! Точность на сдвинутых данных сейчас составляет почти 98 %. Таким образом, мы смогли натренировать модель усваивать пространственные взаимосвязи цифр при их сдвиге на изображении без увеличения сложности модели. Но мы пока не увидели никаких улучшений на инвертированных данных.

Теперь давайте займемся тренировкой модели отфильтровывать фон и белизну цифр, чтобы улучшить способность модели обобщать на инвертированные тестовые данные вне распределения. В следующем ниже исходном коде мы берем 10 % тренировочных данных (`x_train_copy[0:6000]`) и инвертируем их, как мы сделали с тестовыми данными. Почему 10 % вместо всех тренировочных данных? Когда мы хотим натренировать модель что-то отфильтровывать, мы, как правило, можем сделать это, используя всего 10 % распределения всех тренировочных данных.

Далее мы объединяем изначальные тренировочные данные с дополнительными инвертированными тренировочными данными, соединив два тренировочных набора вместе – `x_train` (данные) и `y_train` (метки), – в общей сложности 66 000 изображений (против 60 000) в нашем тренировочном наборе:

```

x_train_invert = np.invert(x_train_copy[0:6000])
x_train_invert = (x_train_invert / 255.0).astype(np.float32)
x_train_invert = x_train_invert.reshape(-1, 28, 28, 1)

y_train_invert = x_train[0:6000]

x_combine = np.append(x_train, x_train_invert, axis=0)
y_combine = np.append(y_train, y_train_invert, axis=0)

model = CNN([16, 32])
datagen = ImageDataGenerator(width_shift_range=0.2)
datagen.fit(x_train_combine)
model.fit_generator(datagen.flow(x_combine, y_combine, batch_size=32),
                    steps_per_epoch= 66000 // 32 , epochs=10)
score = model.evaluate(x_test, y_test, verbose=1)
print("test", score)

```

Отбирает 10 % (копии) тренировочных данных и их инвертирует

Отбирает те же 10 % соответствующих меток

Соединяет два тренировочных набора данных в единый тренировочный набор

Тренирует модель объединенным тренировочным набором данных

Ниже приведен результат нашей тренировки сверточной нейросети:

```
test [0.04763028650498018, 0.9847]
```

Давайте посмотрим, повысит ли это точность на наших альтернативных тестовых данных:

```
inverted [0.13941174189522862, 0.9589]
shifted [0.06449916120804847, 0.979]
```

Красота! Тестовая точность на инвертированных изображениях составляет почти 96 %.

12.2.7 Заключительный тест

В качестве заключительного теста я случайно отобрал «в дикой природе» из результатов поиска изображений в Google изображения рукописной одной цифры. Они включали изображения, которые были раскрашены, нарисованы фломастером, нарисованы кистью и начерчены мелком маленьким ребенком. После того как я провел тестирование, я получил точность всего 40 % со сверточной нейросетью, которую мы только что натренировали в этой главе.

Почему только 40 %, и как бы мы диагностировали причину? Вопрос должен заключаться в том, какое подпопуляционное распределение усвоила модель. Научилась ли модель обобщать контуры цифр независимо от контраста с фоном, или она просто узнала, что цифры бывают либо белыми, либо черными? Что произойдет, если мы проведем тестирование с черной цифрой на сером фоне (вместо белого)?

Тренировочные и тестовые данные из MNIST являются цифрами, нарисованными ручкой или карандашом, поэтому линии тонкие. Некоторые из моих изображений «из дикой природы» были более толстыми, сделанными фломастером, кистью или карандашом. На-

училась ли модель обобщать толщину линий? А как насчет текстуры? Цифры, нарисованные карандашом и кистью, имели неровную текстуру; были ли эти различия в текстуре усвоены как края в сверточных слоях?

В качестве последнего примера предположим, что вы разработали модель для использования на заводе с целью обнаружения дефектов в деталях. Камера находится в фиксированном положении с ракурсом над серой конвейерной лентой, по которой проходят гребни. Все работает хорошо до тех пор, пока однажды владелец не заменит конвейерную ленту гладкой желтой лентой, чтобы привнести немного цвета на завод, и теперь модель обнаружения дефектов отказывает. Что случилось? Дело в том, что поскольку серая конвейерная лента была на всех тренировочных изображениях, она стала частью усвоенных признаков в латентном пространстве, перед тем как перейти к ученической задаче (классификатору). Это похоже на классический случай «собак и волков», в котором все фотографии волков были сделаны зимой. В этом классическом случае, когда натренированной модели была дана фотография собаки со снегом на заднем плане (вне распределения), модель предсказала волка. Здесь модель просто усвоила, что снег означает волка.

Резюме

- Выборочное распределение моделирует параметры популяционного распределения.
- Подпопуляционное распределение моделирует смещение, которое является подмножеством популяционного распределения.
- Если вы тренировали на подпопуляционном распределении и ваша модель не обобщает в производстве на примеры, которые она видит, то производственные данные, скорее всего, находятся вне распределения из подпопуляции, на которой вы тренировали. Это также называется перекосом в обслуживании производственных запросов.
- Добавление более глубоких или более широких слоев и/или большей регуляризации, как правило, не помогает в обобщении на популяцию вне распределения.
- Генерирование тренировочных образцов за счет обогащения изображений в некоторых случаях помогает в обобщении на популяции вне распределения.
- Если обогащения изображений для обобщения недостаточно, то необходимо добавить тренировочные примеры из подпопуляции вне распределения.

13

Конвейер данных

Эта глава охватывает следующие ниже темы:

- понимание распространенных типов форматов данных и хранения тренировочных наборов данных;
- использование формата TensorFlow TFRecord и конвейера tf.data для представлений и преобразований набора данных;
- строительство конвейера данных для подачи данных в модель во время тренировки;
- предобработка с использованием преобразующих слоев TF.Keras, подклассирования слоев и компонентов TFX;
- использование обогащения данных для тренировки моделей под трансляционную, масштабную и видовую инвариантность.

Вы построили свою модель, по мере необходимости используя komponуемые модели. Вы натренировали и перетренировали ее заново, протестировали и протестировали повторно. Теперь вы готовы ее запустить. В последних двух главах вы узнаете, как запускать модель. Выражаясь конкретнее, вы выполните миграцию модели из подготовительной и разведывательной фаз в производственную среду, используя экосистему TensorFlow 2.x в сочетании с TensorFlow Extended (TFX).

В производственной среде такие операции, как тренировка и развертывание, выполняются в виде конвейеров. Преимущество конвейеров заключается в том, что они являются конфигурируемыми,

реиспользуемыми, версионно-контролируемыми и обладают историей. По причине обширности производственного конвейера нам нужны две главы, чтобы охватить его целиком. В этой главе основное внимание уделяется компонентам конвейера данных, которые составляют внешнюю часть производственного конвейера. В следующей главе рассматривается два компонента – тренировка и развертывание.

Давайте начнем с диаграммы, чтобы вы могли увидеть процесс от начала до конца. На рис. 13.1 показан общий вид базового сквозного (end-to-end, аббр. e2e) производственного конвейера.



Рис. 13.1 Базовый сквозной производственный конвейер начинается с конвейера данных, затем переходит к конвейерам тренировки и развертывания

Современный базовый сквозной конвейер машинного обучения начинается со складирования данных, то есть по сути с репозитория тренировочных данных, предназначенного для всех производственных моделей. Число моделей, которые тренирует компания размером с производственное предприятие, варьируется. Но вот несколько примеров из моего опыта за 2019 год. Время между перетренировкой (новой версии) производственной модели сократилось с месячного цикла до недельного, а в некоторых случаях составляет дневной цикл. Google (мой работодатель) перетренировывает более 4000 моделей в день. Складирование данных в таком масштабе является огромным мероприятием.

Из склада данных необходимо эффективно подавать данные для тренировки модели и предоставлять данные точно в срок и без бутылочных горлышек ввода-вывода (I/O). Вышестоящий процесс, который компилирует и собирает пакеты для тренировки, должен делать это достаточно быстро в реальном времени, чтобы не останавливать тренировочное оборудование GPU/CPU.

В масштабах предприятия склад данных обычно распределен по большому или обширному числу вычислительных экземпляров, будь то локально в организации, в облаке либо гибридно, что усложняет эффективную подачу данных в течение тренировки.

Теперь начинается тренировка модели. Однако мы не тренируем одиночный экземпляр модели. Мы тренируем многочисленные экземпляры в параллельном режиме, чтобы отыскивать наилучшую версию, и мы делаем это в несколько стадий, начиная со сбора данных, их подготовки, обогащения и предтренировки до гиперпараметрического поиска для полной тренировки.

Если мы перенесемся во времени на несколько лет назад, то этот конвейерный процесс начинался с того, что эксперты в предметной области выдвигали обоснованные догадки и их автоматизировали. Сегодня эти стадии становятся самообучающимися. Мы продвинулись от автоматизации (с устанавливающими правила экспертами) к автоматическому усвоению, когда машина постоянно учится, самосовершенствуясь под руководством опытного человека. И именно поэтому тренируются многочисленные экземпляры моделей: чтобы автоматически узнавать, какой экземпляр модели станет лучшей натренированной моделью.

Затем идет версионный контроль. Нам требуется средство оценивания нового натренированного экземпляра прошлыми версиями, чтобы отвечать на вопрос о том, является ли новый экземпляр лучше предыдущего. Если да, то ему назначается версия; в противном случае процесс повторяется. А новые версии модели развертываются, чтобы использоваться в производстве.

В этой главе мы рассмотрим перемещение данных со склада, предобработку и пакетирование данных для передачи модельным экземплярам во время тренировки. В следующей главе мы рассмотрим тренировку, перетренировку заново и непрерывную тренировку, валидацию кандидатной модели, версионирование, развертывание и тестирование после развертывания.

13.1 Форматы и хранение данных

Мы начнем с того, что посмотрим на различные форматы хранения изображений для машинного обучения. Исторически данные изображений хранились в одном из следующих форматов:

- формат сжатого изображения (например, JPG);
- формат несжатого RAW-изображения (например, BMP);
- формат высокой размерности (например, HDF5 или DICOM).

С помощью TensorFlow 2.x мы храним изображения в формате TFRecord. Давайте рассмотрим каждый из этих четырех форматов повнимательнее.

13.1.1 Форматы сжатых и сырых изображений

Когда глубокое обучение впервые стало популярным для компьютерного зрения, мы обычно тренировали, беря изображения прямо в сыром формате (raw), после того как эти изображения конвертировались в несжатый формат. Существовало два основных пути подготовки этих данных: извлечение тренировочных пакетов с диска в формате JPG, PNG или другом сжатом формате и извлечение пакетов из сжатых изображений в оперативной памяти (RAM).

Извлечение пакетов с диска

В первом подходе, когда мы строим пакеты для тренировки, мы читаем пакеты изображений с диска в сжатом формате, таком как JPG или PNG. Затем мы разжимаем их в памяти, изменяем размер и выполняем предобработку изображения, например нормализуем пиксельные данные.

Указанный процесс показан на рис. 13.2. В данном примере подмножество изображений JPG, заданных пакетным размером, читается в память, а затем разжимается, и, наконец, его размер изменяется в соответствии с входной формой подлежащей тренировке модели.

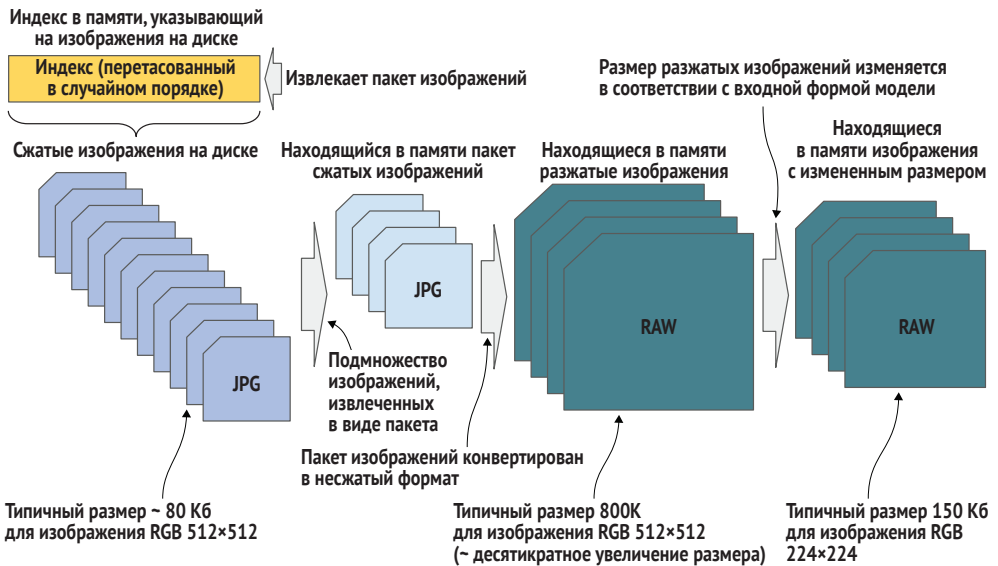


Рис. 13.2 Извлечение сжатых изображений с диска выполняется легко, но обходится дорого при постоянной повторной обработке в целях тренировки

Давайте взглянем на некоторые плюсы и минусы этого метода. Прежде всего его очень легко выполнять. Вот его шаги.

- 1 Создать индекс со всеми путями к изображениям на диске и соответствующим меткам (например, индексный файл CSV).

- 2 Прочитать индекс в память и произвольно перетасовать индекс.
- 3 Извлечь пакет изображений и соответствующие метки в памяти с помощью перетасованного индексного файла.
- 4 Конвертировать изображения в несжатый формат.
- 5 Изменить размер разжатых изображений в соответствии с входной формой подлежащей тренировке модели.

Большой недостаток данного метода заключается в том, что во время тренировки модели приходится повторять предыдущие шаги для каждой эпохи. При этом проблематичным может быть шаг извлечения данных с диска. Указанный шаг может быть связан с вводом-выводом и конкретно зависит от типа дискового хранилища и местоположения данных. В идеале мы хотим, чтобы данные хранились на диске с максимально быстрой операцией доступа на чтение, насколько это возможно, и как можно ближе (путем лимитирования пропускной способности сети) к вычислительному устройству, выполняющему тренировку.

В целях сравнения этого компромисса между содержанием данных на диске и прямо в памяти давайте допустим, что вы используете передовую модель с входной формой ImageNet (224, 224, 3). Этот размер типичен для общего классифицирования изображений, тогда как для обнаружения объектов изображения или сегментирования изображений используется крупный размер, например (512, 512, 3).

Изображение формы (224, 224, 3) требует 150 000 байт памяти ($224 \times 224 \times 3 = 150\,000$). Для того чтобы содержать 50 000 тренировочных изображений непрерывно в памяти во входной форме ImageNet, вам потребуется 8 Гб ($50\,000 \times 150\,000$) оперативной памяти (RAM) – больше, чем нужно для операционной системы, фоновых приложений и тренировки модели. Теперь предположим, что у вас 100 000 тренировочных изображений. Тогда вам понадобится 16 Гб оперативной памяти. Если бы у вас был миллион изображений, то вам понадобилось бы 160 Гб оперативной памяти.

Для этого потребовалось бы много памяти, и иметь все изображения в несжатом формате в памяти, как правило, целесообразно только в случаях малых наборов данных. Для академических и других учебных целей тренировочные наборы данных по обыкновению достаточно малы, чтобы держать несжатые и измененные изображения полностью в памяти. Но в производственных средах, где набор данных слишком велик, чтобы его полностью держать в памяти, необходимо использовать стратегию, включающую извлечение изображений с диска.

Извлечение пакетов из сжатых изображений в оперативной памяти

В этой второй стратегии мы устраняем дисковый ввод-вывод, но все равно разжимаем и изменяем размер в памяти всякий раз, когда изображение появляется в пакете. Устраняя дисковый ввод-вывод, мы избегаем привязанности к вводу-выводу, что в противном слу-

чае замедляло бы тренировку. Например, если тренировка состоит из 100 эпох, то каждое изображение будет разжиматься и изменяться 100 раз, но все сжатые изображения будут оставаться в памяти.

Среднее сжатие JPEG составляет примерно 10:1. Размер сжатого изображения будет зависеть от источника изображения. Например, если изображения сделаны с мобильного телефона с разрешающей способностью 3.5 мегапиксела (3.5 млн пикселей), то размер сжатого изображения составит около 350 000 байт. Если изображения оптимизированы под веб-загрузку в браузере, то изображение без сжатия, как правило, находится в диапазоне от 150 000 до 200 000 байт.

Если допустить, что у вас 100 000 тренировочных изображений, оптимизированных под Веб, то будет достаточно 2 Гб оперативной памяти ($100 \text{ Kб} \times 15 \text{ Kб} = 1.5 \text{ Гб}$). Если у вас миллион тренировочных изображений, то 16 Гб оперативной памяти будет достаточно ($1 \text{ М} \times 15 \text{ Kб} = 15 \text{ Гб}$).

Рисунок 13.3 иллюстрирует этот второй подход, описанный ниже.

- 1 Прочитать все сжатые изображения и соответствующие им метки в память в виде списка.
- 2 Создать индекс ко всем списковым индексам изображений в памяти и соответствующим меткам.
- 3 Перетасовать индекс в случайном порядке.
- 4 Извлечь пакет изображений и соответствующие метки из памяти с помощью перетасованного индексного файла.
- 5 Конвертировать изображения в несжатый формат.
- 6 Изменить размер несжатых изображений.

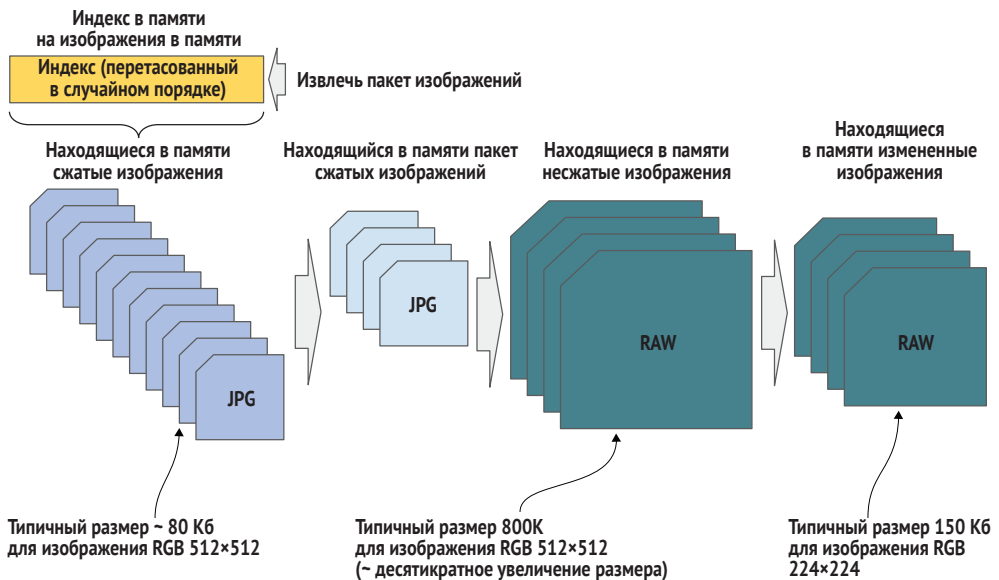


Рис. 13.3 Извлечение сжатых изображений из оперативной памяти устраняет дисковый ввод-вывод, тем самым ускоряя процесс

Этот подход традиционно является разумным компромиссом для наборов данных среднего размера. Давайте допустим, что у нас 200 000 изображений, оптимизированных по размеру под Веб. Нам нужно всего 4 Гб памяти, чтобы держать все сжатые изображения в памяти без повторного чтения с диска. Даже при крупном размере пакета (скажем, 1024 изображения, оптимизированных под Веб) нам потребуется всего 150 Мб памяти, чтобы держать несжатые изображения в памяти – в среднем 150 000 байт на изображение.

Ниже приведены меры, которые я обычно применяю на практике.

- 1 Если несжатый размер моих тренировочных данных меньше или равен моей оперативной памяти, то я выполняю тренировку с несжатыми изображениями в памяти. Это самый быстрый вариант.
- 2 Если сжатый размер моих тренировочных данных меньше или равен моей оперативной памяти, то я выполняю тренировку со сжатыми изображениями в памяти. Это следующий по скорости вариант.
- 3 В противном случае я выполняю тренировку с изображениями, извлекаемыми с диска, либо использую гибридный подход, который рассмотрим далее.

Гибридный подход

Далее давайте рассмотрим гибридный подход к подаче тренировочных образов с диска и из памяти. Зачем это делать? Мы хотим найти золотую середину в компромиссе между доступным пространством памяти и другими ограничениями ввода-вывода, связанными с непрерывным перечитыванием изображений с диска.

В целях выполнения данного подхода мы вернемся к концепции выборочного распределения из главы 12, которое аппроксимирует распределение популяции. Вообразите, что у вас есть 16 Гб памяти, чтобы держать там данные, а предобработанный набор данных после изменения размера составляет 64 Гб. При гибридной подаче мы берем по одному крупному сегменту предобработанных данных за раз (по 8 Гб в нашем примере), который был *стратифицирован* (примеры соответствуют классу распределения тренировочных данных). Затем многократно подаем один и тот же сегмент в нейронную сеть в качестве эпох. Но каждый раз мы обогащаем изображение таким образом, чтобы каждая эпоха была уникальным выборочным распределением всего предобработанного набора изображений.

Я рекомендую этот подход для чрезвычайно крупных наборов данных, таких как миллион изображений. Имея 16 Гб памяти, вы можете держать очень крупные подпопуляции вашего набора данных и достигать схождения при сопоставимых тренировочных пакетах по сравнению с многократным чтением с диска, сокращая при этом время тренировки или требования к вычислительному экземпляру.

Ниже приведены шаги для выполнения гибридной загрузки из памяти / с диска. Этот процесс также изображен на рис. 13.4.

- 1 Создать стратифицированный индекс на предобработанные изображения на диске.
- 2 Поделить стратифицированный индекс на разделы в зависимости от доступной памяти для хранения сегмента в памяти.
- 3 Для каждого сегмента повторять в течение определенного числа эпох:
 - произвольно перетасовывать сегмент в расчете на эпоху;
 - произвольно применять обогащение изображения, чтобы создавать уникальное выборочное распределение в расчете на эпоху;
 - подавать мини-пакеты в нейронную сеть.

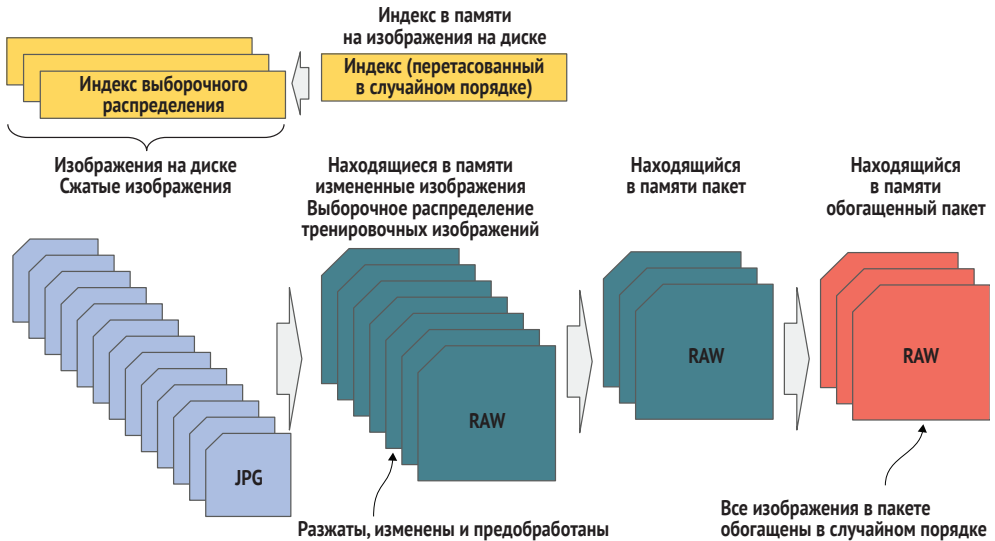


Рис. 13.4 Гибридное извлечение изображений с диска в качестве выборочных распределений тренировочных данных

13.1.2 Формат HDF5

Иерархический формат данных 5 (Hierarchical Data Format 5, аббр. HDF5) долгое время был форматом, традиционно применяемым для хранения данных высокой размерности, таких как спутниковые снимки высокого разрешения. И возможно, вы спросите, что такое *высокая размерность*. Мы ассоциируем этот термин с данными, которые информационно очень плотны в одной размерности и/или имеют много размерностей (такие данные мы называем *многомерными*). Как и в предыдущих обсуждениях в отношении TFRecords, сами по себе эти форматы сокращают объем дискового пространства для хранения совсем незначительно. Вместо этого их предназначение за-

ключается в быстром доступе на чтение, чтобы сокращать издержки ввода-вывода.

HDF5 – это эффективный формат хранения и доступа к крупным объемам многомерных данных, таких как изображения. Его спецификацию для языка Python можно найти на веб-сайте HDF5 (www.h5py.org/). Указанный формат поддерживает объекты набора данных и групповые объекты, а также атрибуты (метаданные) по каждому объекту.

Преимущества использования HDF5 для хранения тренировочных изображений таковы:

- имеет широкое научное применение, как, например, в спутниковых снимках, используемых NASA (см. <http://mng.bz/qevf>);
- оптимизирован под высокоскоростной доступ к срезам данных;
- совместим с синтаксисом NumPy, что позволяет обращаться к данным с диска, как если бы они были в памяти;
- имеет иерархический доступ к многомерным представлениям, свойства и классификации.

Пакет HDF5 для Python можно установить следующим образом:

```
pip install h5py
```

Давайте начнем с создания набора данных с самым базовым представлением HDF5, состоящим из сырых (несжатых) изображений и соответствующих целочисленных меточных данных. В этом представлении мы создаем два объекта набора данных, один для изображений, а другой для соответствующих меток:

```
dataset['images'] : [...]
dataset['labels'] : [...]
```

Следующий ниже исходный код является примером имплементации. Тренировочные данные и метки имеют формат NumPy. Мы открываем файл HDF5 для доступа на запись и создаем два набора данных, один для изображений и другой для меток:

```
from tensorflow.keras.datasets import cifar10
```

```
(x_train, y_train), (x_test, y_test) = cifar10.load_data()
```

Открывает файл HDF5
для доступа на запись

```
with h5py.File('myfile.h5', 'w') as hf:
```

```
    hf.create_dataset("images", data=x_train)
```

```
    hf.create_dataset("labels", data=y_train)
```

Сохраняет тренировочные изображения
в виде набора данных с именем «images»

Сохраняет тренировочные метки в виде
набора данных с именем «labels»

Теперь, когда мы захотим прочитать изображения и метки, мы сначала открываем HDF5 для доступа на чтение. Затем создаем итератор для изображений и меток набора данных. Дескриптор файла HDF5

является объектом-словарем, и мы ссылаемся на наши именованные наборы данных посредством имени набора данных в качестве ключа.

Затем мы снова открываем файл HDF5 для доступа на чтение, а потом создаем итератор HDF5 для изображений и меток набора данных, используя ключи `images` и `labels`. Здесь `x_train` и `y_train` являются псевдонимами итераторов HDF5. Данные на самом деле еще не находятся в памяти:

```
hf = h5py.File('myfile.h5', 'r')  ← Открывает файл HDF5 для доступа на чтение
x_train = hf['images']             ← Создает итератор HDF5 для набора изображений
y_train = hf['labels']             ← Создает итератор HDF5 для набора меток
```

Поскольку в итераторах HDF5 используется синтаксис NumPy, к данным можно обращаться напрямую с помощью операций нарезки массивов NumPy, которые доставляют данные с диска в находящийся в памяти массив NumPy. В следующем ниже исходном коде мы получаем один пакет, используя операцию нарезки изображений (`x_batch`) и соответствующих меток (`y_batch`):

```
x_batch = x_train[0:100]  ← Первые 100 изображений теперь находятся
y_batch = y_train[0:100]  в памяти в виде массива NumPy
```

← Первые 100 меток теперь находятся в памяти в виде массива NumPy

Затем мы прокручиваем в цикле весь набор данных в виде пакетов и отправляем каждый пакет в модель для ее тренировки. Давайте допустим, что в нашем наборе данных HDF5 хранится 50 000 изображений (например, в наборе данных CIFAR-10).

Мы прокручиваем в цикле набор данных HDF5 с пакетным размером 50. Всякий раз мы ссылаемся на следующий последовательный срез массива. Затем итератор каждый раз извлекает 50 изображений из диска и загружает их в `x_batch` в виде находящегося в памяти массива NumPy. Мы делаем то же самое для соответствующих меток, которые загружаются в `y_batch` в виде массива NumPy. Затем передаем пакет изображений и соответствующих меток методу модуля TF.Keras `train_on_batch()`, который выполняет одно пакетное обновление в модели:

```
examples = 50000
batch_size = 50
batches = examples / batch_size
for batch in range(batches):
    x_batch = x_train[batch*batch_size:(batch+1)*batch_size]
    y_batch = y_train[batch*batch_size:(batch+1)*batch_size]
    model.train_on_batch(x_batch, y_batch)
```

← Извлекает следующий пакет из файла HDF5 в качестве находящегося в памяти среза NumPy

← Обновляет модель пакетом

Группы HDF5

Далее мы рассмотрим альтернативное представление хранения данных с использованием функциональности групп, предназначенной

для хранения набора данных в формате HDF5. Этот альтернативный метод обеспечивает более эффективное хранение, исключает хранение меток и способен хранить иерархические наборы данных. В указанном представлении мы создадим отдельную группу для каждого класса (метки) и соответствующего набора данных.

В следующем ниже примере это представление продемонстрировано. У нас есть два класса, кошки (cats) и собаки (dogs), и мы создаем группу для каждого. Внутри обеих групп создаем один набор данных для соответствующих изображений. Обратите внимание, что нам больше не нужно хранить массив меток, так как они подразумеваются именем группы:

```
Group['cats']
    Dataset['images']: [...]
Group['dogs']
    Dataset['images']: [...]
```

Следующий ниже исходный код является примером имплементации, в котором `x_cats` и `x_dogs` – это находящиеся в памяти соответствующие массивы NumPy для изображений кошек и собак:

```
with h5py.File('myfile.h5', 'w') as hf:
    cats = hf.create_group('cats')
    cats.create_dataset('images', data=x_cats)
    dogs = hf.create_group('dogs')
    dogs.create_dataset('images', data=x_dogs)
```

Создает группу для класса кошек
и соответствующий набор данных внутри
группы для хранения изображений кошек

Создает группу для класса собак и соответствующий набор
данных внутри группы для хранения изображений собак

Затем мы читаем пакет из групповой версии кошек и собак. В приведенном ниже примере открываем дескрипторы групп HDF5 для групп кошек и собак. Затем ссылаемся на дескрипторы групп HDF5 с использованием синтаксиса словаря. Например, в целях получения итератора изображений кошек мы ссылаемся на него как `cats['images']`. Потом извлекаем в память 25 изображений из набора кошек и 25 изображений из набора собак, используя срез массива NumPy, как `x_batch`. В качестве последнего шага мы генерируем соответствующие целочисленные метки в `y_batch`. Мы задаем кошкам значение 0 и собакам значение 1:

Открывает дескрипторы групп HDF5 для групп кошек и собак

```
hf = h5py.File('myfile.h5', 'r')
cats = hf['cats']
dogs = hf['dogs']
x_batch = np.concatenate([cats['images'][0:25], dogs['images'][0:25]])
y_batch = np.concatenate([np.full((25), 0), np.full((25), 1)])
```

Извлекает пакет из наборов кошек и собак
внутри соответствующих групп

Создает соответствующие метки

Указанный формат поддерживает иерархическое хранение групп, когда изображения помечены иерархически несколькими метками. Если изображения помечены иерархически, то каждая группа подразделяется дальше на иерархию подгрупп, как показано ниже. Вдобавок мы используем атрибут `Group` для явного закрепления уникального целочисленного значения за соответствующей меткой:

```
Group['cats']
  Attribute: {label: 0}
  Group['persian']:
    Attribute: {label: 100}
    Dataset['images']: [...]
  Group['siamese']:
    Attribute: {label: 101}
    Dataset['images']: [...]
Group['dogs']
  Attribute: {label: 1}
  Group['poodles']:
    Attribute: {label: 200}
    Dataset['images']: [...]
  Group['beagle']:
    Attribute: {label: 201}
    Dataset['images']: [...]
```

В целях имплементирования этого иерархического хранилища мы создаем группы и подгруппы верхнего уровня. В данном примере мы создаем группу верхнего уровня для кошек. Затем, используя дескриптор группы HDF5 для кошек, создаем подгруппы для каждой породы, таких как персидская и сиамская. Далее по каждой подгруппе пород мы создаем набор данных для соответствующих изображений. Вдобавок используем свойство `attrs` для явного закрепления уникального значения за меткой:

Создает группу верхнего уровня для кошек
и закрепляет за ней метку 0 в качестве атрибута

```
with h5py.File('myfile.h5', 'w') as hf:
    cats = hf.create_group('cats')
    cats.attrs['label'] = 0
```

Создает подгруппу второго уровня
в разделе кошки для породы «сиамская»,
закрепляет за ней метку и добавляет
изображения сиамских кошек

```
    breed = cats.create_group('persian')
    breed.attrs['label'] = 100
    breed.create_dataset('images', data=x_cats['persian'])
    breed = cats.create_group('siamese')
    breed.attrs['label'] = 101
    breed.create_dataset('images', data=x_cats['siamese'])
```

Создает подгруппу второго уровня в разделе кошки для породы «персидская»,
закрепляет за ней метку и добавляет изображения персидских кошек

Подытоживая: функциональность групп HDF5 предлагает простой и эффективный метод хранения, предназначенный для доступа

к иерархически помеченным данным, в особенности для наборов данных с многочисленными метками, где метки также имеют иерархическую взаимосвязь. Еще одним распространенным мульти-меточным иерархическим примером является плодоовощная продукция. На вершине иерархии у вас два класса: фрукты и овощи. Под каждым из этих двух классов указан род (например, яблоко, банан, апельсин), а под типом – вид (например, Гренни Смит, Гала, Голден Делишес).

13.1.3 Формат DICOM

В отличие от формата HDF5, который широко используется в спутниковых снимках, формат *цифровой визуализации и коммуникаций в медицине* (Digital Imaging and Communications in Medicine, аббр. DICOM) используется в медицинской визуализации. Форма DICOM фактически является международным стандартом ISO 12052 для хранения и доступа к данным медицинской визуализации, таким как сканы компьютерной томографии и рентгеновские снимки, а также к информации о пациентах. Указанный специализированный формат, который предшествовал HDF5, широко используется во всех системах медицинских исследований и здравоохранения с массой общедоступных деидентифицированных наборов данных о состоянии здоровья. Если вы работаете с данными медицинской визуализации, то вам просто необходимо знать этот формат.

Здесь я представлю несколько основных рекомендаций по использованию данного формата, а также демонстрационный образец. Но если вы специализируетесь либо планируете специализироваться в области медицинской визуализации, то я рекомендую спецификацию DICOM и учебные пособия, размещенные на веб-сайте DICOM (www.dicomstandard.org/).

Пакет DICOM для Python можно установить следующим образом:

```
pip install pydicom
```

Как правило, наборы данных DICOM чрезвычайно велики – сотни гигабайт. Это связано с тем, что указанный формат используется исключительно для медицинской визуализации и обычно состоит из изображений с чрезвычайно высоким разрешением для сегментации и может дополнительно состоять из слоев 3-мерных срезов в каждом изображении.

Pydicom, пакет Python с открытым исходным кодом для медицинских изображений в формате DICOM, предоставляет небольшой набор данных для демонстрационных целей. Мы будем использовать этот набор данных для наших примеров кодирования. Давайте начнем с импортирования пакета Pydicom и получения тестового набора данных CT_small.dcm:

```
import pydicom
from pydicom.data import get_testdata_files

dcm_file = get_testdata_files('CT_small.dcm')[0]
```

Этот метод Pydicom возвращает список имен файлов с демонстрационными наборами данных

В DICOM помеченные данные также содержат табличные данные, такие как информация о пациентах. Изображение, метка и табличные данные могут использоваться для тренировки *мультимодальной модели* (модели, имеющей два или более входных слоя), и каждый входной слой имеет свой тип данных (например, изображение или числовые данные).

Давайте посмотрим, как изображения и метки читаются из файлового формата DICOM. Мы прочитаем демонстрационный набор данных, который имитирует реально существующий пример медицинских визуализационных данных пациента, и начнем с получения некоторой базовой информации об этом наборе данных. Каждый набор данных содержит крупный объем информации о пациентах, к которой можно обращаться в качестве словаря. В этом примере показано лишь несколько полей, большинство из которых были деидентифицированы. Дата исследования указывает на время, когда было сделано изображение, а модальность – это тип визуализации (в данном случае скан компьютерной томографии):

```
dataset = pydicom.dcmread(dcm_file)
for key in ['PatientID', 'PatientName', 'PatientAge', 'PatientBirthDate',
            'PatientSex', 'PatientWeight', 'StudyDate', 'Modality']:
    print(key, dataset[key])
```

PatientID (0010, 0020) Patient ID	LO: '1CT1'
PatientName (0010, 0010) Patient's Name	PN:
'CompressedSamples^CT1'	
PatientAge (0010, 1010) Patient's Age	AS: '000Y'
PatientBirthDate (0010, 0030) Patient's Birth Date	DA: ''
PatientSex (0010, 0040) Patient's Sex	CS: 'O'
PatientWeight (0010, 1030) Patient's Weight	DS: "0.0"
StudyDate (0008, 0020) Study Date	DA: '20040119'
Modality (0008, 0060) Modality	CS: 'CT'

Наконец, мы извлечем изображение и выводим его на экран, как показано ниже и на рис. 13.5:

```
rows = int(dataset.Rows)
cols = int(dataset.Columns)
print("Image size.....: {rows:d} x {cols:d}, {size:d} bytes".format(
    rows=rows, cols=cols, size=len(dataset.PixelData)))

plt.imshow(dataset.pixel_array, cmap=plt.cm.bone)
plt.show()
```

Более подробную информацию о доступе и анализе изображений DICOM можно найти в стандарте, а также в учебных пособиях для Pydicom (<https://pydicom.github.io/>).




Рис. 13.5 Изображение, извлеченное из файла DICOM

13.1.4 Формат TFRecord

TFRecord – это стандарт TensorFlow хранения и доступа к наборам данных для тренировки с помощью TensorFlow. Указанный двоичный формат изначально был разработан с целью эффективной сериализации структурированных данных с использованием определений буферного формата протокола Google, но благодаря коллективу разработчиков TensorFlow претерпел дальнейшее развитие с целью эффективной сериализации неструктурированных данных, таких как изображения, видео и текст. Помимо того что организация TensorFlow рекомендует использовать этот формат для тренировочных данных, он был легко интегрирован в экосистему TF, в том числе в `tf.data` и TFX.

Ниже, опять же, мы просто попробуем этот формат, чтобы понять, как его можно использовать для изображений с целью тренировки сверточных нейросетей. Для получения более подробной информации о формате и стандарте ознакомьтесь с учебными пособиями (www.tensorflow.org/tutorials/load_data/tfrecord).

Рисунок 13.6 дает наглядный общий вид использования формата TFRecords для тренировочного набора данных в качестве иерархии представлений `tf.data`. Соответствующие три шага таковы.

- 1 На верхнем уровне находится `tf.data.Dataset`. Это находящееся в памяти представление тренировочного набора данных.
- 2 Следующим уровнем является последовательность из одной или нескольких TFRecords. Это хранилище набора данных на диске.
- 3 На нижнем уровне находятся записи `tf.Example`; каждая содержит один пример данных.

Теперь давайте опишем эти взаимосвязи снизу вверх. Мы будем конвертировать каждый пример в тренировочных данных в объект `tf.Example`. Например, если у нас 50 000 тренировочных изображе-

ний, то у нас будет 50 000 записей `tf.Example`. Далее мы сериализуем эти записи, чтобы они имели быстрый доступ для чтения на диске в виде файлов `TfRecord`. Эти файлы предназначены не для произвольного доступа, а для последовательного, чтобы минимизировать доступ на чтение, поскольку они будут писаться один раз, но читаться много раз.

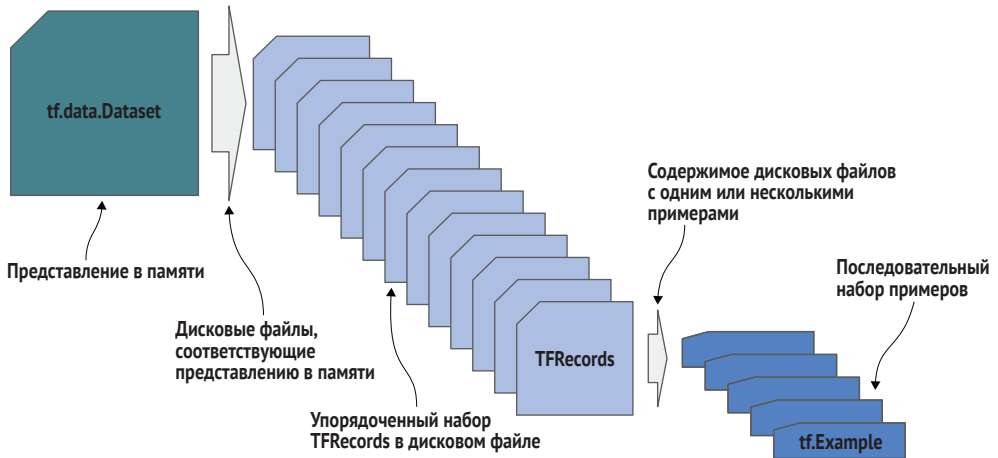


Рис. 13.6 Иерархические взаимосвязи `tf.data`, `TfRecords` и `tf.Example`

Для крупных объемов данных записи обычно делятся на несколько файлов `TfRecord`, чтобы еще больше минимизировать времена доступа на чтение, специфичные для устройства хранения. Хотя размер каждой сериализованной записи `tf.Example`, число примеров, тип устройства хранения и распределение наилучшим образом определяют размер разделов, коллектив разработчиков TensorFlow рекомендует в качестве общего эмпирического правила от 100 до 200 Мб каждый.

TF.EXAMPLE: ПРИЗНАКИ

Формат `tf.Example` имеет сходство как со словарем Python, так и с объектами JSON. Пример (такой как изображение) и соответствующие метаданные (например, метка) инкапсулированы внутри библиотечного класса `tf.Example`. Объект этого класса состоит из списка из одной или нескольких записей `tf.train.Feature`. Каждая запись `Feature` может быть одним из следующих ниже типов данных:

- `tf.train.ByteString`;
- `tf.train.FloatList`;
- `tf.train.Int64List`.

Тип `tf.train.ByteString` используется для последовательностей байтов или символов. Примером байтов могут быть закодированные или сырые байты изображения, а примером символов может быть

текстовый строковый литерал для модели обработки ЕЯ (NLP) или имя класса для метки.

Тип `tf.train.FloatList` используется для 32-битовых (одинарной точности) или 64-битовых (двойной точности) чисел с плавающей точкой. Примером может служить непрерывное действительное значение для столбца в структурированном наборе данных.

Тип `tf.train.Int64List` используется как для 32-битовых, так и для 64-битовых целых чисел со знаком и без знака, а также для булевых значений. Что касается целочисленного типа, то он используется, например, для категориального значения столбца в структурированном наборе данных или скалярного значения метки.

Для кодирования изображения в формат `tf.Example` используется несколько распространенных методов:

- признаковая запись для кодирования изображения;
- признаковая запись для формы изображения (с целью реконструкции);
- признаковая запись для соответствующей метки.

Ниже приведен генерический пример определения объекта `tf.train.Example` для кодирования изображения; пометка /здесь идут записи/ является местозаполнителем словарных статей для данных об изображении и соответствующих метаданных, которые мы обсудим впоследствии. Обратите внимание, что TensorFlow ссылается на формат как `tf.Example`, а на тип данных как `tf.train.Example`. Поначалу это может дезориентировать.

```
example = tf.train.Example(features = { /здесь идут записи/ })
```

TF.EXAMPLE: СЖАТОЕ ИЗОБРАЖЕНИЕ

В следующем ниже примере мы создадим объект `tf.train.Example` для изображения, которое не было декодировано (оно находится в сжатом дисковом формате). Преимущество такого подхода заключается в том, что мы используем наименьший объем дискового пространства при хранении в виде части `TFRecord`. Недостатком является то, что всякий раз, когда мы читаем запись TF с диска, подавая данные в нейронную сеть во время тренировки, изображения должны быть несжатыми; это компромисс между временем и пространством.

В следующем ниже примере исходного кода мы определяем функцию для конвертирования дискового файла изображения (параметр `path`) и соответствующей метки (параметр `label`) следующим образом:

- дисковое изображение читается в первый раз и разжимается в сырое растровое изображение с использованием метода `cv2.imread()` библиотеки `OpenCV`, чтобы получить форму изображения (строки, столбцы, каналы);
- дисковое изображение читается во второй раз с помощью метода `tf.io.gfile.GFile()` в своем изначальном сжатом формате.

Обратите внимание, что метод `tf.io.gfile.GFile()` эквивалентен `file.open()`, но если изображение хранится в корзине GCS, то указанный метод оптимизирован под производительность чтения/записи ввода-вывода;

- экземпляр `tf.train.Example()` инстанцируется с тремя словарными записями объекта `Features`:
 - `image` – тип `BytesList` для несжатых (изначальных дисковых данных) изображений;
 - `label` – тип `Int64List` для значения метки;
 - `shape` – тип `Int64List` для кортежа (строки, высота, каналы) формы изображения.

Если допустить, что в нашем примере размер дискового изображения составляет 24 000 байт, то размер записи `tf.train.Example` в файле `TFRecord` составит около 25 000 байт.

```
import tensorflow as tf
import numpy as np
import sys
import cv2
```

```
def TFExampleImage(path, label):
    ''' Изначальная сжатая версия изображения '''
```

```
    image = cv2.imread(path) | Использует OpenCV для получения
    shape = image.shape      | формы изображения
```

```
    with tf.io.gfile.GFile(path, 'rb') as f: | Использует TensorFlow для чтения
    disk_image = f.read()                  | сжатого изображения из корзины GCS
```

Создает
признаковую запись
для байтовых
данных сжатого
изображения

```
    return tf.train.Example(features = tf.train.Features(feature = {
        'image': tf.train.Feature(bytes_list = tf.train.BytesList(value =
                                [disk_image])),
        'label': tf.train.Feature(int64_list = tf.train.Int64List(value =
                                [label])),
```

Создает признаковую
запись для
соответствующей
метки

```
        'shape': tf.train.Feature(int64_list = tf.train.Int64List(value =
                                [shape[0], shape[1], shape[2]]))
    })
```

Создает признаковую запись
для соответствующей формы
в виде $H \times W \times C$

```
    example = TFExampleImage('example.jpg', 0)
    print(example.ByteSize())
```

TF.EXAMPLE: НЕСЖАТОЕ ИЗОБРАЖЕНИЕ

В следующем ниже примере исходного кода мы создадим запись `tf.train.Example` для хранения несжатой версии изображения в `TFRecord`. Преимущество этого подхода заключается в том, что изображение читается с диска только один раз, и его не нужно разжимать всякий раз, когда запись читается из `TFRecord` на диске во время тренировки.

Его недостатком является то, что размер записи будет существенно больше, чем у версии дискового изображения. В предыдущем

примере, при условии 95%-го сжатия JPEG, размер записи в TFRecord будет составлять 500 000 байт. Обратите внимание, что в кодировке изображения в форме `ByteList` удерживается формат `np.uint8`.

```
def TFExampleImageUncompressed(path, label):
    ''' Несжатая версия изображения '''
```

<p>Создает признаковую запись для байтовых данных несжатого изображения</p>	<pre> image = cv2.imread(path) shape = image.shape return tf.train.Example(features = tf.train.Features(feature = { 'image': tf.train.Feature(bytes_list = tf.train.BytesList(value = [image.tostring()])), 'label': tf.train.Feature(int64_list = tf.train.Int64List(value = [label])), 'shape': tf.train.Feature(int64_list = tf.train.Int64List(value = [shape[0], shape[1], shape[2]])) })))</pre>	<p>Использует OpenCV для чтения несжатого изображения</p>
<p>Создает признаковую запись для соответствующей метки</p>	<pre> example = TFExampleImageUncompressed('example.jpg', 0) print(example.ByteSize())</pre>	<p>Создает признаковую запись для соответствующей формы в виде $H \times W \times C$</p>

TF.ПРИМЕР: ПОДХОД ПОЛНОЙ ГОТОВНОСТИ К МАШИННОМУ ОБУЧЕНИЮ

В нашем последнем примере исходного кода мы сначала нормализуем пиксельные данные (путем деления на 255) и сохраняем нормализованные изображения. Преимущество этого метода заключается в том, что нам не нужно нормализовывать пиксельные данные всякий раз, когда запись читается из TFRecord на диске во время тренировки. Его недостатком является то, что теперь пиксельные данные хранятся как тип `np.float32`, что в четыре раза больше, чем соответствующий тип `np.uint8`. Если исходить из того же примера изображения, то размер TFRecord сейчас будет составлять 2 млн байт.

```
def TFExampleImageNormalized(path, label):
    ''' Нормализованная версия изображения '''
```

<p>Создает признаковую запись для байтовых данных несжатого изображения</p>	<pre> image = (cv2.imread(path) / 255.0).astype(np.float32) shape = image.shape return tf.train.Example(features = tf.train.Features(feature = { 'image': tf.train.Feature(bytes_list = tf.train.BytesList(value = [image.tostring()])), 'label': tf.train.Feature(int64_list = tf.train.Int64List(value = [label])), 'shape': tf.train.Feature(int64_list = tf.train.Int64List(value = [shape[0], shape[1], shape[2]])) })))</pre>	<p>Использует OpenCV для чтения несжатого изображения и нормализации пиксельных данных</p>
<p>Создает признаковую запись для соответствующей метки</p>	<pre> example = TFExampleImageNormalized('example.jpg', 0) print(example.ByteSize())</pre>	<p>Создает признаковую запись для соответствующей формы в виде $H \times W \times C$</p>

TFRecord: ВЫГРУЗКА ЗАПИСИ НА ДИСК

Теперь, когда мы построили запись `tf.train.Example` в памяти, следующий шаг – записать ее в файл `TFRecord` на диске. Мы сделаем это с целью последующей подачи тренировочных данных с диска во время тренировки модели.

В целях максимизации эффективности выгрузки в дисковое хранилище и загрузки из него записи сериализуются в строковый формат для хранения в буферном формате протокола Google. В следующем ниже исходном коде `tf.io.TFRecordWriter` – это функция, которая будет выгружать сериализованную запись в файл в этом формате. При записи `TFRecord` на диск в имени файла также традиционно используется суффикс `.tfrecord`.

Создает объект, пишущий в файл `TFRecord`

```
with tf.io.TFRecordWriter('example.tfrecord') as writer:
    writer.write(example.SerializeToString())
```

Пишет одну сериализованную запись `tf.train.Example` в файл

Дисковый файл `TFRecord` может содержать несколько записей `tf.train.Example`. Следующий ниже исходный код пишет несколько сериализованных записей `tf.train.Example` в файл `TFRecord`:

Создает объект, пишущий в файл `TFRecord`

```
with tf.io.TFRecordWriter('example.tfrecord') as writer:
    for example in examples:
        writer.write(example.SerializeToString())
```

Пишет каждый `tf.train.Example` последовательно в файл `TFRecord`

TFRecord: ЗАГРУЗКА ЗАПИСИ С ДИСКА

Следующий ниже пример исходного кода демонстрирует способ чтения каждой записи `tf.train.Example` из файла `TFRecord` в последовательном порядке. Мы исходим из того, что файл `example.tfrecord` содержит несколько сериализованных записей `tf.train.Example`.

Функция `tf.compat.v1.io.record_iterator()` создает итераторный объект, который при использовании в инструкции `for` будет читать в память каждую сериализованную запись `tf.train.Example` в последовательном порядке. Метод `ParseFromString()` используется для десериализации данных в находящийся в памяти формат `tf.train.Example`.

Создает итератор для прокручивания в цикле записей `tf.train.Example` в последовательном порядке

```
iterator = tf.compat.v1.io.tf_record_iterator('example.tfrecord')
for entry in iterator:
    example = tf.train.Example()
    example.ParseFromString(entry)
```

Прокручивает каждую запись в цикле и конвертирует сериализованное строковое значение в `tf.train.Example`

В качестве альтернативы можно читать и прокручивать в цикле набор записей `tf.train.Example` из файла `TFRecord`, используя класс `tf.data.TFRecordDataset`. В следующем ниже примере исходного кода мы делаем вот что:

- инстанцируем объект `tf.data.TFRecordDataset` в качестве итератора дисковых записей;
- определяем словарь `feature_description`, чтобы указать способ десериализации сериализованных записей `tf.train.Example`;
- определяем вспомогательную функцию `_parse_function()` для взятия сериализованной записи `tf.train.Example (proto)` и ее десериализации с использованием словаря `feature_description`;
- применяем метод `map()` для итеративной десериализации каждой записи `tf.train.Example`.

Создает итератор дискового набора данных	dataset = tf.data.TFRecordDataset('example.tfrecord')	Создает словарное описание для десериализации <code>tf.train.Example</code>	Функция последовательного разбора записей <code>tf.train.Example</code>
Разбирает каждую запись в наборе данных, используя функцию <code>map()</code>	<pre>feature_description = { 'image': tf.io.FixedLenFeature([], tf.string), 'label': tf.io.FixedLenFeature([], tf.int64), 'shape': tf.io.FixedLenFeature([3], tf.int64), }</pre> <pre>def _parse_function(proto): ''' Разобрать следующую сериализованную запись tf.train.Example, используя признаковое описание ''' return tf.io.parse_single_example(proto, feature_description)</pre> <pre>parsed_dataset = dataset.map(_parse_function)</pre>		

Если распечатать `parsed_dataset`, то результат должен быть таким:

```
<MapDataset shapes: {image: (), shape: (), label: ()},
types: {image: tf.string, shape: tf.int64, label: tf.int64}>
```

13.2 Подача данных

В предыдущем разделе мы обсудили вопросы структурирования и хранения данных для тренировки как в памяти, так и на диске. В этом разделе рассматривается доставка данных в конвейер с помощью `tf.data`, то есть модуля TensorFlow для строительства конвейера набора данных. Его функциональность предусмотрена для строительства конвейеров из различных источников, таких как тензоры NumPy и TensorFlow в памяти и файлы `TFRecords` на диске.

Конвейер набора данных создается как генератор при помощи класса `tf.data.Dataset`. Отсюда `tf.data` относится к модулю Python, тогда как `tf.data.Dataset` относится к конвейеру набора данных. Конвейер данных используется как для предобработки, так и для подачи данных для тренировки модели.

Сначала мы рассмотрим строительно конвейера данных из находящихся в памяти данных NumPy, а затем займемся строительством конвейера из дисковых файлов TFRecords.

13.2.1 NumPy

В целях создания генератора находящегося в памяти набора данных NumPy мы используем метод `from_tensor_slices()` конвейера `tf.data.Dataset`. Указанный метод принимает в качестве параметра тренировочные данные, которые задаются в виде кортежа: (изображения, метки).

В следующем ниже исходном коде мы создаем конвейер `tf.data.Dataset` из данных CIFAR-10 в формате NumPy, которые указываем в качестве параметрического значения (`x_train`, `y_train`):

```
from tensorflow.data import Dataset
from tensorflow.keras.datasets import cifar10
(x_train, y_train), (x_test, y_test) = cifar10.load_data()
dataset = Dataset.from_tensor_slices((x_train, y_train))
```

Создает генератор набора данных
для находящихся в памяти
тренировочных данных
NumPy

Обратите внимание, что набор данных является генератором и, следовательно, не является индексруемым¹. Нельзя написать `dataset[0]` и ожидать получения первого элемента. Это вызовет исключение.

Далее мы прокрутим набор данных в цикле. Но мы хотим делать это пакетами, как мы делаем при подаче данных с помощью метода `fit()` в TF.Keras, и мы указываем размер пакета. В следующем ниже примере исходного кода мы используем метод `batch()`, чтобы задать размер пакета для набора данных равным 128. Обратите внимание, что пакет (`batch`) не является свойством. Он не изменяет состояние существующего набора данных, но создает новый генератор. Вот почему мы назначаем `dataset.batch(128)` обратно изначальной переменной `dataset`. TensorFlow ссылается на эти типы методов набора данных как на преобразования набора данных.

Затем мы прокручиваем набор данных в цикле и для каждого пакета (`x_batch`, `y_batch`) печатаем форму. По каждому пакету мы получаем (128, 32, 32, 3) для изображений и (128, 1) для соответствующих меток:

```
dataset = dataset.batch(128)
for x_batch, y_batch in dataset:
    print(x_batch.shape, y_batch.shape)
```

Преобразовывает набор данных, чтобы его
прокручивать в цикле пакетами по 128 единиц

Прокручивает набор данных
пакетами по 128 единиц

¹ В оригинале используется термин `subscriptable`. В языке Python объекты, содержащие другие объекты или типы данных, такие как строковые литералы, списки, кортежи и словари, являются `subscriptable`, т. е. индексруемые. – Прим. перев.

Если повторить ту же итерацию цикла `for` во второй раз, то мы не получим никакого результата. Почему? Что случилось? По умолчанию генераторы наборов данных прокручивают набор данных только один раз. В целях непрерывного повтора, как если бы у нас было несколько эпох, в качестве еще одного преобразования набора данных мы используем метод `repeat()`. Поскольку мы хотим, чтобы каждая эпоха видела отличающуюся случайную упорядоченность пакетов, в качестве еще одного преобразования набора данных мы используем метод `shuffle()`. Описанная последовательность преобразований набора данных продемонстрирована ниже:

```
dataset = dataset.shuffle(1024)
dataset = dataset.repeat()
dataset = dataset.batch(128)
```

Методы преобразования набора данных также могут образовывать цепочку. Их часто можно увидеть выстроенными друг с другом в цепочку. Приведенная ниже одна строка кода идентична предыдущей последовательности из трех строк:

```
dataset = dataset.shuffle(1024).repeat().batch(128)
```

Важен порядок применения преобразований. Если сначала использовать функцию `repeat()`, а затем преобразование `shuffle()`, то в первую эпоху пакеты не будут рандомизированы.

Также обратите внимание, что мы задаем значение для преобразования `shuffle()`. Это значение указывает число примеров, которые необходимо извлекать из набора данных в память и перетасовывать за прием. Например, если у нас достаточно памяти для хранения там всего набора данных, то мы устанавливаем это значение равным суммарному числу примеров в тренировочных данных (например, 50 000 для CIFAR-10). Это приведет к перетасовке всего набора данных сразу – полной перетасовке. Если мы этого не делаем, то необходимо рассчитать объем памяти, который можно сэкономить, и разделить на размер каждого примера в памяти. Допустим, у нас 2 Гб свободного места, и каждый пример в памяти составляет 200 000 байт. В этом случае мы бы установили размер равным 10 000 (2 Гб / 200 Кб).

В следующем ниже примере исходного кода мы тренируем простую сеть данными CIFAR-10, используя `tf.data.Dataset` в качестве конвейера данных. Метод `fit()` совместим с генераторами `tf.data.Dataset`. Вместо передачи сырых изображений и соответствующих меток мы передаем генератор набора данных, заданный переменной `dataset`.

Поскольку это генератор, метод `fit()` не знает, сколько пакетов будет приходиться на эпоху. Поэтому нам нужно дополнительно указать значение параметра числа шагов на эпоху (`steps_per_epoch`) и установить его равным числу пакетов в тренировочных данных. В нашем случае мы рассчитали это как число примеров в тренировочных данных, деленное на размер пакета (50000 // 128):

```

from tensorflow.keras import Sequential
from tensorflow.keras.layers import Conv2D, ReLU, Activation,
from tensorflow.keras.layers import BatchNormalization, Dense, Flatten

model = Sequential()
model.add(Conv2D(16, (3,3), strides=1, padding='same', input_shape=(32, 32,
3)))
model.add(BatchNormalization())
model.add(ReLU())
model.add(Conv2D(32, (3,3), strides=1, padding='same'))
model.add(BatchNormalization())
model.add(ReLU())
model.add(Flatten())
model.add(Dense(10, activation='softmax'))
model.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
               metrics=['acc'])
batches = 50000 // 128
model.fit(dataset, steps_per_epoch=batches, epochs=5, verbose=1)

```

Тренирует с помощью метода fit(),
используя генератор набора данных

Вычисляет число пакетов
в наборе данных

В этом разделе мы рассмотрели строительство конвейера данных из находящегося в памяти источника данных, например в формате тензора Numpy или TensorFlow. Далее разберем строительство конвейера данных из дискового источника данных с использованием файлов TFRecords.

13.2.2 TFRecord

В целях создания дискового генератора набора данных из файлов TFRecord мы используем метод TFRecordDataset() модуля tf.data. Указанный метод принимает в качестве параметра путь к одному файлу TFRecord или список путей к нескольким файлам TFRecord. Как описано в предыдущем разделе, каждый файл TFRecord может содержать один или несколько тренировочных примеров, таких как изображения, и в целях повышения производительности ввода-вывода тренировочные данные могут охватывать несколько файлов TFRecord.

Приведенная ниже строка кода создает генератор набора данных для одного файла TFRecord:

```
dataset = tf.data.TFRecordDataset('example.tfrecord')
```

В приведенном ниже примере исходного кода создается генератор набора данных для нескольких файлов TFRecord, когда набор данных охватывает несколько файлов TFRecord:

```
dataset = tf.data.TFRecordDataset(['example1.tfrecord', 'example2.tfrecord'])
```

Далее мы должны указать генератору набора данных, как разбирать каждую сериализованную запись в файле TFRecord. Мы используем метод map(), позволяющий определять функцию разбора конкретно-

го примера TFRecord, которая будет применяться к каждому примеру (преобразовывать его) всякий раз, когда пример читается с диска.

В следующем ниже примере мы сначала определяем признаковое описание `feature_description` с детализацией разбора специфичных для TFRecord записей. Используя предыдущий пример, мы исходим из того, что компоновкой нашей записи является ключ/значение изображения в байтовой кодировке, ключ/значение целочисленной метки и ключ/значение целочисленной формы из трех элементов. Затем мы применяем метод `tf.io.parse_single_example()`, чтобы выполнить разбор сериализованного примера в файле TFRecord, основываясь на признаковом описании:

```
feature_description = {
    'image': tf.io.FixedLenFeature([], tf.string),
    'label': tf.io.FixedLenFeature([], tf.int64),
    'shape': tf.io.FixedLenFeature([3], tf.int64),
}

def _parse_function(proto):
    ''' Выполнить разбор следующего сериализованного примера
        tf.train.Example, используя признаковое описание '''
    return tf.io.parse_single_example(proto, feature_description)

dataset = dataset.map(_parse_function)
```

Создает словарное описание для десериализации примера `tf.train.Example`

Функция последовательного разбора примера `tf.train.Example`

Выполняет разбор каждой записи в наборе данных с помощью функции `map()`

Теперь давайте сделаем еще несколько преобразований набора данных, а затем взглянем на то, что мы имеем, когда прокручиваем дисковый файл TFRecord. В приведенном ниже примере исходного кода мы применяем преобразование, чтобы перетасовать и установить размер пакета равным 2. Затем перебираем набор данных пакетами по два примера и выводим на экран соответствующие ключи/значения метки (`label`) и формы (`shape`):

```
dataset = dataset.shuffle(4).batch(2)
for entry in dataset:
    print(entry['label'], entry['shape'])
```

Создает итератор для дисковой базы данных

Прокручивает в цикле дисковый файл TFRecord пакетами из двух примеров

Следующий ниже результат показывает, что каждый пакет состоит из двух примеров, метки в первом пакете равны 0 и 1, а метки во втором пакете равны 1 и 0, и все изображения имеют размер (512, 512, 3):

```
tf.Tensor([0 1], shape=(2,), dtype=int64) tf.Tensor(
[[512 512  3]
 [512 512  3]], shape=(2, 3), dtype=int64)
tf.Tensor([1 0], shape=(2,), dtype=int64) tf.Tensor(
[[512 512  3]
 [512 512  3]], shape=(2, 3), dtype=int64)
```

TFRECORD: СЖАТОЕ ИЗОБРАЖЕНИЕ

До этого места в книге мы не обращались к формату, в котором кодируются сериализованные изображения. Как правило, изображение

кодируется либо в сжатом формате (например, JPEG), либо в несжатом формате (raw). В следующем ниже примере исходного кода мы вносим дополнительный шаг в `_parse_function()`, чтобы декодировать изображение из сжатого формата (JPEG) в несжатый формат с помощью `tf.io.decode_jpg()`. Отсюда, поскольку каждый пример читается с диска и десериализуется, теперь изображения декодируются:

```
dataset = tf.data.TFRecordDataset(['example.tfrecord'])

feature_description = {
    'image': tf.io.FixedLenFeature([], tf.string),
    'label': tf.io.FixedLenFeature([], tf.int64),
    'shape': tf.io.FixedLenFeature([3], tf.int64),
}

def _parse_function(proto):
    ''' Выполнить разбор следующего сериализованного примера
        tf.train.Example, используя признаковое описание
    '''
    example = tf.io.parse_single_example(proto, feature_description)
    example['image'] = tf.io.decode_jpg(example['image']) ←
    return example
                                                    Декодирует сжатое
                                                    изображение JPEG

dataset = dataset.map(_parse_function)
```

TFRECORD: НЕСЖАТОЕ ИЗОБРАЖЕНИЕ


В следующем ниже примере исходного кода закодированные изображения находятся в несжатом формате в файле TFRecord. Следовательно, нам не нужно их распаковывать, но нам все равно нужно декодировать закодированный список байтов в формат сырой битовой карты с помощью `tf.io.decode_raw()`.

Сырые декодированные данные в этом месте представляют собой 1-мерный массив, поэтому нам нужно реформировать их в изначальную форму. После получения сырых декодированных данных мы получаем изначальную форму из ключа/значения `shape`, а затем реформируем сырые данные с помощью `tf.reshape()`:

```
dataset = tf.data.TFRecordDataset(['tfrec/example.tfrecord'])

feature_description = {
    'image': tf.io.FixedLenFeature([], tf.string),
    'label': tf.io.FixedLenFeature([], tf.int64),
    'shape': tf.io.FixedLenFeature([3], tf.int64),
}
                                                    Декодирует изображение
                                                    в несжатый сырой формат

def _parse_function(proto):
    ''' Выполнить разбор следующего сериализованного примера
        tf.train.Example, используя признаковое описание
    '''
    example = tf.io.parse_single_example(proto, feature_description)
    example['image'] = tf.io.decode_raw(example['image'], tf.uint8) ←
```



13.3 Предобработка данных

Ранее мы рассматривали форматы данных, хранение и чтение тренировочных данных из памяти или с диска, а также некоторую предобработку данных. В этом разделе мы рассмотрим предобработку подробнее. Сначала разберем вопрос переноса предобработки из вышестоящего конвейера данных в предстержневой модельный компонент, а затем рассмотрим вопрос настройки конвейера предобработки с помощью TFX.

13.3.1 Предобработка с помощью предстержня

Вы должны помнить, что при выпуске TensorFlow 2.0 одна из рекомендаций состояла в переносе предобработки в граф. Мы могли использовать два подхода. Во-первых, могли встраивать ее в граф. Во-вторых, могли выполнять предобработку независимо от модели, но делать ее по принципу «подключи и играй» таким образом, чтобы предобработка происходила на графе и могла быть сменной. Выгоды от предстержневого подхода «подключи и играй» заключаются в следующем:

- реиспользуемый и сменный компонент в конвейере тренировки и развертывания;
- выполняется на графе, а не выше по потоку на CPU, устраняя потенциальную привязку к вводу-выводу при подаче данных в модель для ее тренировки.

На рис. 13.7 изображено использование предстержней «подключи и играй» для предобработки. На этом рисунке показан набор предстержневых компонентов «подключи и играй», из которых можно выбирать во время тренировки или развертывания модели. Требование к прикреплению предстержня состоит в том, чтобы его выходная форма соответствовала входной форме модели.

Предстержни имеют два требования, чтобы работать по принципу «подключи и играй» с существующими моделями, натренированными и ненатренированными:

- данные на выходе из предстержня должны совпадать с данными на входе в модель. Например, если модель принимает на входе данные в форме (224, 224, 3) – такие как стоковая модель ResNet50, – то на выходе из предстержня тоже должно быть (224, 224, 3);

- входная форма предстержня должна совпадать с входным источником, будь то для тренировки или предсказания. Например, входной источник может иметь размер, отличный от того, на котором была натренирована модель, и предстержень был натренирован усваивать оптимальный метод изменения размера изображений.

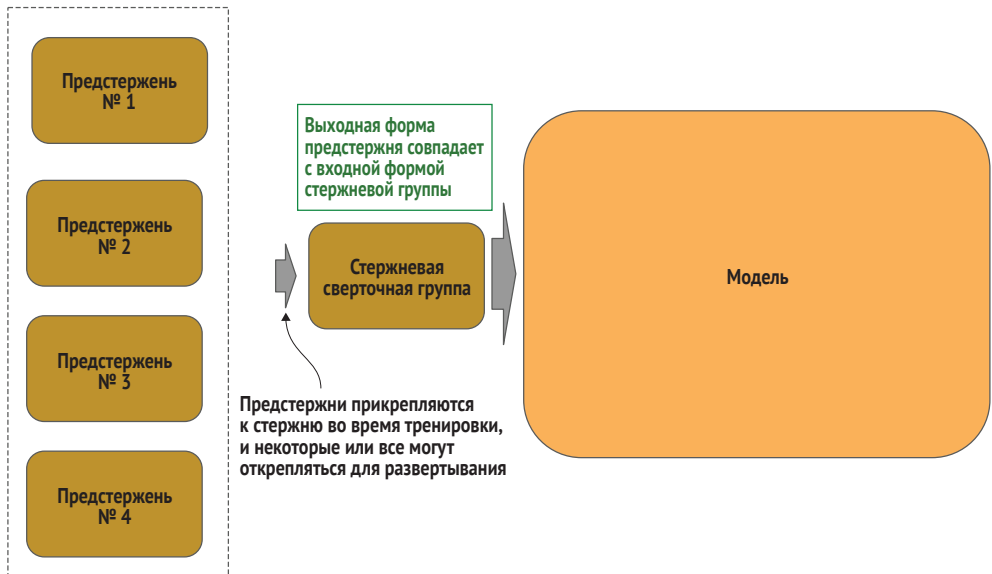


Рис. 13.7 Предстержни «подключи и играй» могут быть сменными во время тренировки и развертывания

Предстержни «подключи и играй» обычно делятся на два типа:

- остается с моделью после развертывания для предсказания. Например, предстержень манипулирует изменением размера и нормализацией входного источника, когда запрос на предсказание состоит из сырых байтов несжатого изображения;
- используется только в течение тренировки и не используется после развертывания. Например, предстержень выполняет случайное обогащение изображения для усвоения трансляционной и масштабной инвариантности во время тренировки, устраняя потребность в конфигурировании конвейера данных для обогащения изображения.

Мы рассмотрим два метода строительства предстержня для переноса предобработки данных в граф. Первый метод для этой цели добавляет слои в TF.Keras 2.x, а второй использует подклассирование для создания своих собственных конкретно-прикладных предобрабатывающих слоев.

ПРЕДОБРАБАТЫВАЮЩИЕ СЛОИ TF.KERAS

Для дальнейшего содействия и поощрения переноса предобработки в граф в TF.Keras 2.2 и последующих версиях были введены новые слои, специально предназначенные для предобработки. Это устранило потребность в использовании подклассирования для строительства распространенных шагов предобработки. В этом разделе рассматриваются три таких слоя: Rescaling, Resizing и CenterCrop. Полный список см. в документации TF.Keras (<http://mng.bz/7jqe>).

На рис. 13.8 изображено прикрепление предстержня «подключи и играй» к существующей модели путем применения оборточного технического приема. Здесь создается второй экземпляр модели, который мы называем *оборточной моделью*. Используя последовательный API, например, обертка будет состоять из двух компонентов: сначала добавляется предстержень, а затем добавляется существующая модель. В целях присоединения существующей модели к предстержню выходная форма предстержня должна совпадать с входной формой существующей модели.



Рис. 13.8 Оборточная модель прикрепляет предстержень к существующей модели

В следующем ниже примере исходного кода имплементирован предстержень «подключи и играй», который мы добавляем в существующую модель перед тренировкой. Сначала мы создаем ненадтренированную модель CovNet с двумя сверточными (Conv2D) слоями соответственно по 16 и 32 фильтра. Затем разглаживаем (Flatten) карты признаков в 1-мерный вектор, без редукции размерности, в качестве бутылочного слоя, а потом идет заключительный плотный (Dense) слой для классифицирования. Мы будем использовать эту модель ConvNet в качестве модели, которую хотим натренировать и развернуть.

Далее мы инстанцируем еще одну пустую модель, которую будем называть оберточной (wrapper) моделью. Обертка будет состоять из двух частей: предстержня и ненадтренированной модели ConvNet. Для предстержня мы добавляем предобрабатывающий слой Rescaling, чтобы нормализовывать целочисленные пиксельные данные между значениями с плавающей точкой в интервале от 0 до 1. Поскольку предстержень будет входным слоем в оберточную модель, мы добавляем параметр (input_shape=(32, 32, 3)) для задания входной формы. Так как Rescaling не изменяет размер данных на входе, данные на выходе из предстержня совпадают с данными на входе в модель.

Наконец, мы тренируем оберточную модель и используем оберточную модель для предсказания. Таким образом, как для тренировки, так и для предсказания нормализация целочисленных пиксельных данных теперь является частью оберточной модели, выполняемой на графе, а не выше по потоку на CPU.

```

from tensorflow.keras import Sequential
from tensorflow.keras.layers import Conv2D, ReLU, Activation,
from tensorflow.keras.layers import BatchNormalization, Dense, Flatten
from tensorflow.keras.layers.experimental.preprocessing import Rescaling

model = Sequential()
model.add(Conv2D(16, (3,3), strides=1, padding='same', input_shape=(32, 32, 3)))
model.add(BatchNormalization())
model.add(ReLU())
model.add(Conv2D(32, (3,3), strides=1, padding='same'))
model.add(BatchNormalization())
model.add(ReLU())
model.add(Flatten())
model.add(Dense(10, activation='softmax'))

wrapper = Sequential()
wrapper.add(Rescaling(scale=1.0/255, input_shape=(32, 32, 3)))

wrapper.add(model)
wrapper.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
                metrics=['acc'])

from tensorflow.keras.datasets import cifar10
(x_train, y_train), (x_test, y_test) = cifar10.load_data()
wrapper.fit(x_train, y_train, epochs=5, batch_size=32, verbose=1)
wrapper.evaluate(x_test, y_test)
```

Импортирует предобрабатывающий слой для перешкалирования

Строит простую модель ConvNet

Строит предстержень с Rescaling

Добавляет предстержень в ConvNet

Тренирует и тестирует модель ConvNet с предстержнем

Предстержень «подключи и играй» может иметь более одного предобрабатывающего слоя, как показано на рис. 13.9, например изменение размера входного изображения с последующим перешкалированием пиксельных данных.

На этом рисунке показано, что поскольку перешкалирование не изменяет выходную форму, выходная форма из предыдущего

слоя изменения размера должна совпадать с входной формой стержневой группы.



Рис. 13.9 Предстержень с двумя преобразующими слоями

Следующий ниже исходный код имплементирует предстержень «подключи и играй», который выполняет две функции: изменяет размер входных данных и нормализует пиксельные данные. Мы начнем с создания той же ConvNet, что и в предыдущем примере. Затем создаем оберточную модель с двумя преобразующими слоями: один для изменения размера изображения (Resizing) и другой для нормализации (Rescaling). В этом примере данные на входе в ConvNet имеют форму (28, 28, 3). Мы используем предстержень для изменения размера входных данных с (32, 32, 3) на (28, 28, 3), чтобы совпадать с ConvNet, и нормализуем пиксельные данные:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Conv2D, ReLU, BatchNormalization,
from tensorflow.keras.layers import Dense, Flatten
from tensorflow.keras.layers.experimental.preprocessing import Rescaling
from tensorflow.keras.layers.experimental.preprocessing import Resizing

from tensorflow.keras.datasets import cifar10

(x_train, y_train), (x_test, y_test) = cifar10.load_data()

model = Sequential()
model.add(Conv2D(16, (3,3), strides=1, padding='same', input_shape=(28, 28, 3)))
model.add(BatchNormalization())
```

```

model.add(ReLU())
model.add(Conv2D(32, (3,3), strides=1, padding='same'))
model.add(BatchNormalization())
model.add(ReLU())
model.add(Flatten())
model.add(Dense(10, activation='softmax'))

wrapper = Sequential()
wrapper.add(Resizing(height=28, width=28, input_shape=(32, 32, 3)))
wrapper.add(Rescaling(scale=1.0/255))
wrapper.add(model)
wrapper.compile(loss='sparse_categorical_crossentropy', optimizer='adam',
                metrics=['acc'])
wrapper.fit(x_train, y_train, epochs=5, batch_size=32, verbose=1)
wrapper.evaluate(x_test, y_test)

```

Добавляет предстержень в оберточную модель

Создает оберточную модель

Добавляет ConvNet в модель и тренирует ее

Теперь, когда мы натренировали модель, мы можем удалить предстержень и использовать модель для предсказательного вывода. В следующем ниже примере мы исходим из допущения, что тестовые изображения уже имеют размер (28, 28, 3), совпадающий с нашей ConvNet, и мы нормализуем пиксельные данные выше по потоку от модели. Мы знаем, что первые два слоя оберточной модели являются предстержем, а значит, наша опорная натренированная модель начинается с третьего слоя; следовательно, мы задаем переменную `model` равной `wrapper.layers[2]`. Теперь можно выполнять предсказательный вывод с помощью опорной модели без предстержня:

```

x_test = (x_test / 255.0).astype(np.float32)
model = wrapper.layers[2]
model.evaluate(x_test, y_test)

```

Предобработка данных происходит выше по потоку на CPU

Получает опорную модель без предстержня

Выполняет вычисление (предсказание) с помощью опорной модели

ВЫСТРАИВАНИЕ ПРЕДСТЕРЖНЕЙ В ЦЕПОЧКУ

На рис. 13.10 изображено выстраивание предстержней в цепочку; один предстержень останется после развертывания модели, а другой будет удален при развертывании модели. Здесь мы создаем две оберточные модели: внутреннюю и внешнюю обертки. Внутренняя обертка содержит предобрабатывающий предстержень, который останется в модели после развертывания, а внешняя обертка содержит предстержень обогащения изображений, который будет удален из модели при развертывании. В случае тренировки мы тренируем внешнюю оберточную модель, а в случае развертывания развертываем внутреннюю оберточную модель.

В нашем последнем примере мы выстроим в цепочку два предстержня. Первый предстержень используется для тренировки, а затем удаляется для предсказательного вывода, а второй остается

с моделью. В первом (внутреннем) предстержне мы выполняем нормализацию целочисленных пиксельных данных (Rescaling). Во втором (внешнем) предстержне мы выполняем обрезку по центру (CenterCrop) входных изображений для тренировки. Мы также задаем входной размер для второго предстержня любой высоты и ширины: (None, None, 3). Как следствие во время тренировки мы можем подавать во второй предстержень изображения разных размеров, и он будет обрезать их по центру до формы (32, 32, 3), которая затем передается на вход в первый нормализующий предстержень.

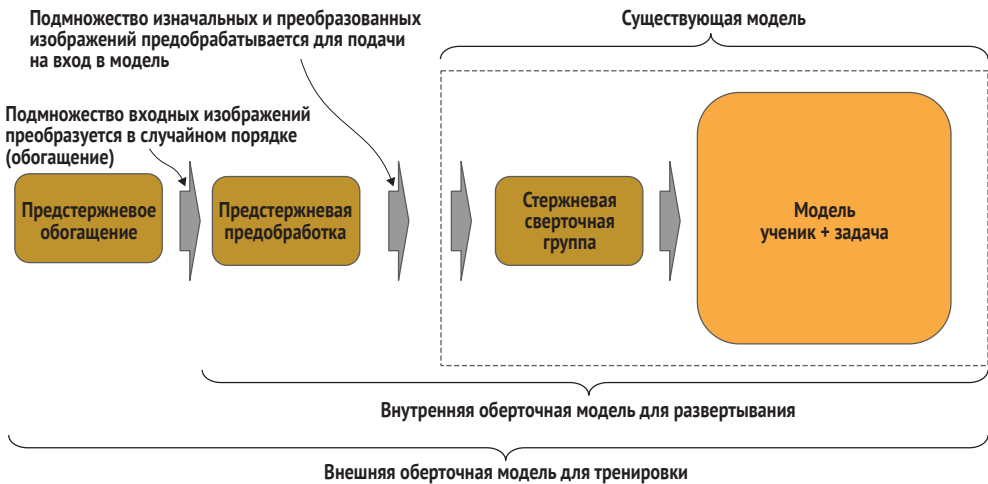


Рис. 13.10 Предстержни, выстроенные в цепочку, – внутренний предстержень остается с моделью после развертывания, а внешний предстержень удаляется

Наконец, после того как тренировка закончена, мы удаляем второй (внешний) предстержень и делаем предсказательный вывод без обрезки по центру:

```
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Conv2D, ReLU, BatchNormalization,
from tensorflow.keras.layers import Dense, Flatten
from tensorflow.keras.layers.experimental.preprocessing import Rescaling,
from tensorflow.keras.layers.experimental.preprocessing import CenterCrop

from tensorflow.keras.datasets import cifar10

(x_train, y_train), (x_test, y_test) = cifar10.load_data()

model = Sequential()  ← Строит модель ConvNet
model.add(Conv2D(16, (3,3), strides=1, padding='same', input_shape=(32, 32, 3)))
model.add(BatchNormalization())
model.add(ReLU())
model.add(Conv2D(32, (3,3), strides=1, padding='same'))
model.add(BatchNormalization())
model.add(ReLU())
```



```

model.add(Flatten())
model.add(Dense(10, activation='softmax'))
model.compile(loss='sparse_categorical_crossentropy',
              optimizer='adam', metrics=['acc'])

wrapper1 = Sequential()
wrapper1.add(Rescaling(scale=1.0/255, input_shape=(32, 32, 3)))
wrapper1.add(model)
wrapper1.compile(loss='sparse_categorical_crossentropy',
                optimizer='adam', metrics=['acc'])

wrapper2 = Sequential()
wrapper2.add(CenterCrop(height=32, width=32, input_shape=(None, None, 3)))
wrapper2.add(wrapper1)
wrapper2.compile(loss='sparse_categorical_crossentropy',
                 optimizer='adam', metrics=['acc'])

wrapper2.fit(x_train, y_train, epochs=5, batch_size=32, verbose=1)
wrapper2.layers[1].evaluate(x_test, y_test)

```

Прикрепляет первый предстержень для нормализации изображений во время тренировки и предсказательного вывода

Выполняет предсказательный вывод только с первым предстержнем

Прикрепляет второй предстержень для обрезки изображений по центру во время тренировки

Тренирует модель с первым и вторым предстержнями

Подклассирование слоев TF.Keras

В качестве альтернативы использованию встроенных предобрабатывающих слоев TF.Keras можно создавать свои собственные конкретно-прикладные предобрабатывающие слои путем подклассирования слоев. Это бывает целесообразно, когда вам нужен конкретно-прикладной шаг предобработки, который не встроен в предобрабатывающие слои TF.Keras.

Все предопределенные слои в TF.Keras подклассированы из класса `TF.Keras.Layer`. В целях создания своего собственного конкретно-прикладного слоя необходимо выполнить следующее:

- 1 создать класс, который является подклассом (наследует) класса `TF.Keras.Layer`;
- 2 переопределить инициализатор `__init__()`, а также методы `build()` и `call()`.

Теперь давайте построим нашу собственную версию предобрабатывающего слоя `Rescaling` с помощью подклассирования. В следующем примере имплементации исходного кода мы определяем класс `Rescaling`, который наследует от `TF.Keras.Layer`. Далее мы переопределяем инициализатор `__init__()`. В опорном классе `Layer` инициализатор принимает два параметра:

- `input_shape` – входная форма входных данных модели при использовании в качестве первого слоя в модели;
- `name` – определяемое пользователем имя для этого экземпляра слоя.

Мы передаем эти два параметра инициализатору опорного класса `Layer` посредством вызова метода `super()`.

Все остальные параметры инициализатора `__init__()` являются параметрами, специфичными для слоя (конкретно-прикладными). Для класса `Rescaling` мы добавляем параметр `scale` и сохраняем его значение в объекте класса.

Далее мы переопределяем метод `build()`. Этот метод вызывается, когда мы компилируем (`compile()`) модель или привязываем один слой к другому с помощью функционального API. Опорный метод принимает параметр `input_shape`, который определяет входную форму слоя. Опорный параметр `self.kernel` задает форму ядра для слоя; форма ядра определяет число параметров. Если бы у нас действительно были усваиваемые параметры, то мы бы установили форму ядра и способ его инициализации. Поскольку `Rescaling` не имеет усваиваемых параметров, то мы устанавливаем его равным `None`.

Наконец, мы переопределяем метод `call()`. Этот метод вызывается, когда граф выполняется для тренировки или предсказательного вывода. Опорный метод принимает `inputs` в качестве параметра, то есть входной тензор слоя, и указанный метод возвращает выходной тензор. В нашем случае мы будем умножать каждое пиксельное значение во входном тензоре на коэффициент `scale`, установленный при инициализации слоя, и выдавать перешкалированный тензор.

Мы добавляем декоратор `@tf.function`, чтобы сообщить инструменту TensorFlow AutoGraph (www.tensorflow.org/api_docs/python/tf/autograph), что он должен конвертировать исходный код Python в этом методе в графовые операции в модели. Инструмент AutoGraph, введенный в TensorFlow 2.0, представляет собой прекомпилятор, который может конвертировать различные операции Python в статические графовые операции. За счет этого обеспечивается перевод исходного кода Python, который может конвертироваться в статические графовые операции, с исполнения выше по потоку на CPU на исполнение на графе. Несмотря на то что в конверсии поддерживаются многие конструкторы языка Python, данная конверсия ограничена графовыми операциями на «неусердных»¹ тензорах, то есть не требующих немедленного вычисления.

Определяет конкретно-прикладной слой, используя подклассирование класса `Layer`

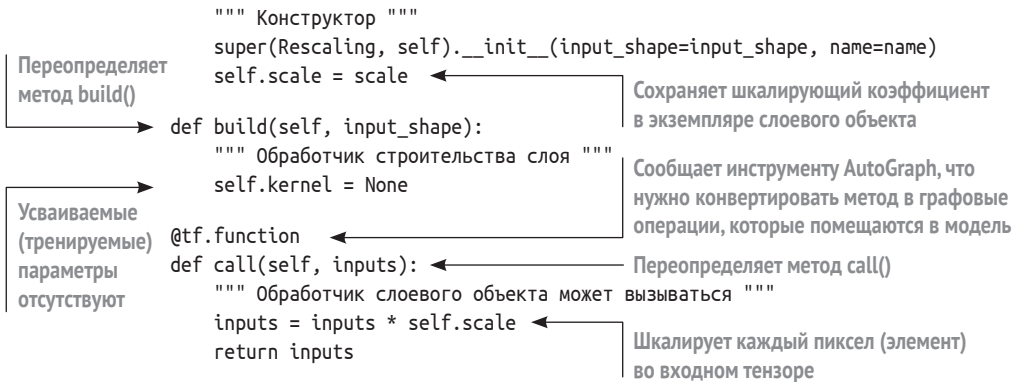
```
import tensorflow as tf
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Conv2D, ReLU, Activation,
from tensorflow.keras.layers import BatchNormalization, Dense, Flatten
from tensorflow.keras.layers import Layer
```

```
class Rescaling(Layer):
```

```
    """ Конкретно-прикладной преобразующий слой """
    def __init__(self, scale, input_shape=None, name=None):
```

Переопределяет инициализатор
и добавляет входной параметр `scale`

¹ В оригинале «non-eager tensor» – это тензор, работающий в усердном (eager) режиме, когда операции выполняются немедленно по мере их вызова из Python. – Прим. перев.



Для получения подробной информации о подклассировании классов Layer и Model ознакомьтесь с различными учебными пособиями и примерами в форме блокнотов Jupyter по подклассированию от коллектива разработчиков TensorFlow, такими как «Создание новых слоев и моделей с помощью подклассирования» (Making New Layers and Models via Subclassing, <http://mng.bz/my54>).

13.3.2 Предобработка с помощью расширенного TensorFlow (TF Extended)

Ранее мы обсуждали строительство конвейеров данных из низкоуровневых компонентов. Здесь мы увидим способы строительства конвейеров данных с использованием компонентов более высокого уровня, которые включают в себя больше шагов, используя расширенный TensorFlow.

TensorFlow Extended (TFX) – это производственный сквозной конвейер. Настоящий раздел охватывает часть TFX, касающуюся конвейера данных, как показано на рис. 13.11.

На высоком уровне компонент ExampleGen принимает данные из источника набора данных. Компонент StatisticsGen анализирует примеры из набора данных и выдает статистику распределения набора данных. Компонент SchemaGen, обычно используемый для структурированных данных, выводит схему данных из статистики набора данных. Например, он может определять типы объектов, такие как категориальные или числовые, типы данных, диапазоны и устанавливать политики данных, например способ обработки отсутствующих данных. Компонент ExampleValidator отслеживает тренировочные данные и данные, подаваемые в качестве службы, на предмет аномалий на основе схемы данных. Эти четыре компонента в совокупности составляют библиотеку валидации данных TFX (TFX Data Validation).

Компонент Transform выполняет преобразования данных, такие как конструирование/выработка признаков, предобработка данных и обогащение данных. Этот компонент составляет библиотеку преобразований TFX (TFX Transform).

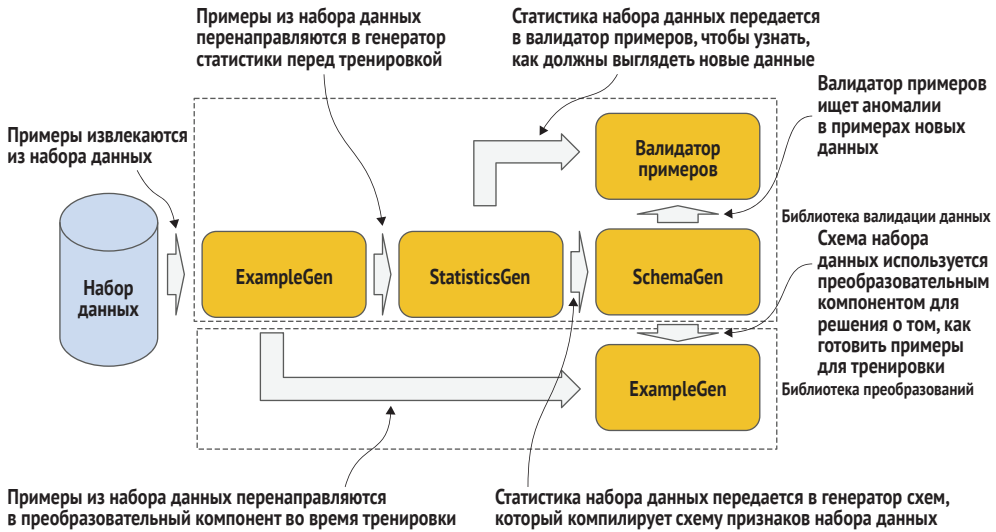


Рис. 13.11 Конвейер данных TFX

Пакет TFX не является частью релиза TensorFlow 2.x, и поэтому его необходимо будет устанавливать отдельно, следующим образом:

```
pip install tfx
```

Остальная часть этого подраздела охватывает каждый из этих компонентов только на высоком уровне. Подробные ссылки и учебные пособия см. в документации TensorFlow по TFX (www.tensorflow.org/tfx).

Далее давайте создадим фрагмент исходного кода для импортирования модулей и классов, которые мы будем использовать во всех последующих примерах исходного кода:

Импортирует утилиты для чтения наборов данных из внешних источников

```
from tfx.utils.dsl_utils import external_input
from tfx.components import ImportExampleGen
from tfx.components import StatisticsGen, SchemaGen, ExampleValidator
from tfx.components import Transform
from tfx.orchestration.experimental.interactive.interactive_context import
InteractiveContext
```

Импортирует оркестровку конвейера TFX

Импортирует экземпляр компонента ExampleGen для TFRecords

Импортирует остальные компоненты конвейера данных TFX

В последующих примерах исходного кода модуль оркестровки конвейера TFX будет использоваться для интерактивной демонстрации. Приведенные ниже последовательности исходного кода настраивают конвейер, но ничего не происходит до начала оркестровки, когда конвейер выполняется.

```
context = InteractiveContext() ← Инстанцирует интерактивную оркестровку конвейера
```

EXAMPLEGEN

Компонент `ExampleGen` является точкой входа в конвейер данных TFX. Его цель состоит в том, чтобы извлекать пакеты примеров из набора данных. Он поддерживает широкий спектр форматов наборов данных, включая файлы CSV, `TfRecords` и Google BigQuery. На выходе из `ExampleGen` получаются записи `tf.Example`.

В следующем ниже примере исходного кода инстанцируется компонент `ExampleGen` для набора данных на диске в формате `TfRecord` (например, изображения). Он состоит из двух шагов.

Давайте начнем со второго шага. Мы инстанцируем компонент `ExampleGen` как подкласс `ImportExampleGen`, где инициализатор принимает в качестве параметра входной источник примеров (`input=examples`).

Теперь давайте вернемся на шаг назад и определим соединитель с входным источником. Поскольку входным источником являются данные `TfRecords`, мы используем утилитный метод TFX `external_input()` для увязки соединителя между `TfRecords` на диске и нашим экземпляром подкласса `ImportExampleGen`:

```
examples = external_input('tfrec')
example_gen = ImportExampleGen(input=examples)
context.run(example_gen)  ← Исполняет конвейер
```

Инстанцирует компонент `ExampleGen`, в котором данные `TfRecords` являются входным источником

STATISTICSGEN

Компонент `StatisticsGen` генерирует статистику набора данных из входного источника примеров. Эти примеры могут быть либо тренировочными/оценочными данными, либо данными, подаваемыми в качестве службы (последние здесь не рассматриваются). В следующем ниже примере исходного кода мы генерируем статистику для тренировочных/оценочных данных. Мы инстанцируем экземпляр компонента `StatisticsGen()` и передаем инициализатору источник примеров. Здесь источником примеров являются данные на выходе из нашего экземпляра `example_gen` в предыдущем примере исходного кода. Выходные данные задаются посредством свойства `outputs` класса `ExampleGen`, то есть словарем, для примеров (`examples`) в виде пар ключ/значение:

```
statistics_gen = StatisticsGen(
    examples=example_gen.outputs['examples'])
context.run(statistics_gen)
statistics_gen.outputs['statistics']._artifacts[0]
```

Инстанцирует компонент `StatisticsGen` с входными данными, получаемыми на выходе из `ExampleGen`

Исполняет конвейер

Выводит на экран интерактивный результат в виде статистики

Данные на выходе из последней строки исходного кода будут выглядеть примерно так, как показано ниже. Свойство `uri` – это локальный каталог, в котором хранится статистика. Свойство `split_names`

указывает на два набора статистических данных: один для тренировки и другой для оценивания:

Artifact of type '**ExampleStatistics**' (uri: /tmp/tfx-interactive-2020-05-28T19_02_20.322858-8g1v59q7/StatisticsGen/statistics/2) at 0x7f9c7a1414d0

.type	<class 'tfx.types.standard_artifacts.ExampleStatistics'>
.uri	/tmp/tfx-interactive-2020-05-28T19_02_20.322858-8g1v59q7/StatisticsGen/statistics/2
.span	0
.split_names	["train", "eval"]

SCHEMA GEN

Компонент SchemaGen генерирует схему из статистики набора данных. В следующем ниже примере исходного кода мы генерируем схему из статистики тренировочных/оценочных данных. Мы инстанцируем экземпляр компонента Schemagen() и передаем инициализатору источник статистики набора данных. В нашем примере источником статистики являются данные на выходе из экземпляра statistics_gen в предыдущем примере исходного кода. Выходные данные задаются посредством свойства outputs класса StatisticsGen, то есть словарем, для статистики (statistics) в виде пар ключ/значение:

```

schema_gen = SchemaGen(
    statistics=statistics_gen.outputs['statistics'])
context.run(schema_gen)
schema_gen.outputs['schema']._artifacts[0]
```

Инстанцирует компонент SchemaGen с входными данными, получаемыми на выходе из ExampleGen

Выводит на экран интерактивный результат в виде схемы

Данные на выходе из последней строки исходного кода будут выглядеть примерно так, как показано ниже. Свойство uri – это локальный каталог, в котором хранится схема. Файловое имя схемы будет schema.pbtxt.

Artifact of type '**Schema**' (uri: /tmp/tfx-interactive-2020-05-28T19_02_20.322858-8g1v59q7/SchemaGen/schema/4) at 0x7f9c500d1790

.type	<class 'tfx.types.standard_artifacts.Schema'>
.uri	/tmp/tfx-interactive-2020-05-28T19_02_20.322858-8g1v59q7/SchemaGen/schema/4

В нашем примере содержимое файла schema.pbtxt будет выглядеть следующим образом:

```

feature {
  name: "image"
  value_count {
```

```

        min: 1
        max: 1
    }
    type: BYTES
    presence {
        min_fraction: 1.0
        min_count: 1
    }
}
feature {
    name: "label"
    value_count {
        min: 0
        max: 1
    }
    type: INT
    presence {
        min_fraction: 1.0
        min_count: 1
    }
}
feature {
    name: "shape"
    value_count {
        min: 3
        max: 3
    }
    type: INT
    presence {
        min_fraction: 1.0
        min_count: 1
    }
}
}

```

EXAMPLEVALIDATOR

Компонент `ExampleValidator` выявляет аномалии в наборе данных, используя в качестве входных данных как статистику набора данных, так и схему. В следующем ниже примере исходного кода мы выявляем аномалии из статистики и схемы тренировочных/оценочных данных. Мы инстанцируем экземпляр компонента `ExampleValidator()` и передаем инициализатору источник статистики набора данных и схему. В нашем примере источниками статистики и схемы являются выходные данные соответственно наших экземпляров `statistics_gen` и `schema_gen` в предыдущих примерах исходного кода.

```

example_validator = ExampleValidator(
    statistics=statistics_gen.outputs['statistics'],
    schema=schema_gen.outputs['schema'])
context.run(example_validator)
example_validator.outputs['anomalies']._artifacts[0]

```

Инстанцирует компонент `ExampleValidator`

Выводит на экран интерактивный результат в виде аномалий

Данные на выходе из последней строки исходного кода будут выглядеть примерно так, как показано ниже. Свойство `uri` – это локальный каталог, в котором хранится информация об аномалиях, если таковые будут сохранены.

Artifact of type 'ExampleAnomalies' (uri:) at 0x7f9c780cbdd0

.type	<class 'tfx.types.standard_artifacts.ExampleAnomalies'>
.uri	
.span	0

TRANSFORM

Компоненты Transform выполняют преобразования набора данных, поскольку во время тренировки или предсказательного вывода примеры извлекаются в пакеты. Преобразования набора данных традиционно представляют собой конструирование/выработку признаков для структурированных данных и предобработку данных.

В следующем ниже примере исходного кода мы преобразовываем пакеты примеров из набора данных. Мы инстанцируем компоненты Transform(). Инициализатор принимает три параметра: входной источник с подлежащими преобразованию примерами (`examples`), схема данных (`schema`) и конкретно-прикладной скрипт Python для выполнения преобразования (например, `my_preprocessing_fn.py`). Мы не будем описывать, как составлять конкретно-прикладные скрипты Python с преобразованиями; для получения более подробной информации ознакомьтесь с учебником TensorFlow по компонентам TFX (<http://mng.bz/5WqA>).

```
transform = Transform(
    examples=example_gen.outputs['examples'],
    schema=schema_gen.outputs['schema'],
    module_file='my_preprocessing_fn.py')
context.run(transform)
```

В следующем разделе описываются способы инкорпорирования обогащения изображений в существующий конвейер данных, например созданный с использованием `tf.data` и/или с использованием предстержней.

13.4 Обогащение данных

На протяжении многих лет *обогащение (аугментация) изображений (данных)* преследовало различные цели. Сначала на него смотрели как на средство расширения (увеличения) существующего набора данных большим числом изображений для тренировки, делая это путем выполнения некоторых случайных преобразований существую-

щих изображений. Впоследствии исследователи выяснили, что определенные типы обогащения могут расширять возможности модели по обнаружению, такие как инвариантность и окклюзия.

В этом разделе показаны способы добавления обогащения изображений в существующий конвейер данных. Мы начнем с базовых концепций, лежащих в основе обогащения изображений, и с того, как оно помогает модели обобщать на примеры, на которых она не тренировалась. Затем перейдем к методам интеграции в конвейер `tf.data`. Наконец, мы узнаем, как интегрировать его с помощью преобразующих слоев в предстержне, который прикрепляется к вашей модели во время тренировки, а затем открепляется для предсказательного вывода.

В этом разделе основное внимание отводится общепринятым методам обогащения и имплементации расширения способностей вашей модели к обнаружению относительно инвариантности. Далее мы дадим определение инвариантности и объясним, почему она важна.

13.4.1 Инвариантность

Сегодня мы не смотрим на обогащение изображений просто как на внесение дополнительных примеров в тренировочный набор. Вместо этого оно является средством тренировки модели быть инвариантной трансляционно, масштабно и к видовому порту за счет конкретной цели генерировать дополнительные изображения из существующих изображений.

Хорошо, тогда что все это значит? Это значит, что мы хотим распознавать объекты на изображении (или в видеокадре) независимо от местоположения на изображении (трансляция), размера объекта (масштаб) и перспективы просмотра (видовой порт). Обогащение изображений позволяет тренировать модели быть инвариантными, не требуя дополнительных реальных помеченных человеком данных.

Обогащение изображений функционирует путем произвольного преобразования изображений в тренировочном наборе данных для различных трансляций, масштабов и видовых портов. В исследовательских работах на практике традиционно выполняются следующие четыре типа обогащения изображений:

- произвольная обрезка по центру;
- произвольный переворот;
- произвольный поворот;
- произвольный сдвиг.

Давайте рассмотрим эти четыре типа подробно.

Произвольная обрезка по центру

При *обрезке* мы берем порцию изображения. Традиционно обрезка имеет прямоугольную форму. Обрезка по центру имеет квадрат-

ную форму и расположена по центру изначального изображения (рис. 13.12). Размер обрезки часто варьируется, поэтому в некоторых случаях это малая часть изображения, а в других – большая часть. Затем размер обрезанного изображения изменяется, становясь равным входному для модели размеру.

Указанное преобразование способствует тренировке модели под масштабную инвариантность, поскольку мы увеличиваем размер объекта (объектов) на изображении в случайном порядке. Возможно, вы задаётесь вопросом, а не могут ли эти случайные обрезания вырезать все или слишком много интересующих объектов, приводя к бесполезным изображениям. В типичной ситуации это не так по следующим ниже причинам:

- объекты переднего плана (интересующие объекты), как правило, появляются в центре изображений или вблизи него;
- мы устанавливаем минимальный размер обрезки, предотвращая, чтобы она была настолько мала, что не содержала бы полезных данных;
- вырезание краев объекта способствует тренировке модели усваивать окклюзию, при которой другие объекты закрывают часть интересующего объекта.




Рис. 13.12 Произвольная обрезка по центру

Произвольный переворот

При *перевороте* мы переворачиваем изображение по горизонтальной или вертикальной оси. Если переворачивать по вертикальной оси, то получится зеркальное изображение. Если переворачивать по горизонтальной оси, то получится перевернутое изображение. Указанное преобразование способствует тренировке модели усваивать инвариантность к видовому порту.

Вы, возможно, подумаете, что в реально существующем приложении в некоторых случаях зеркальное или перевернутое изображение не имеет смысла. Например, вы, вероятно, скажете, что зеркальное отражение знака «стоп» или же перевернутый грузовик не имеет смысла. Может быть, так оно и есть. А возможно, знак «стоп» просматривается в зеркале заднего вида? Или, может быть, ваша машина перевернулась, и из вашего видового порта грузовик действительно выглядит перевернутым.

Случайные перевороты способствуют еще одной вещи – они помогают усваивать существенные признаки объектов, отделенных от фона, независимо от фактического видового порта, когда модель развертывается для реальных предсказаний.

Произвольный поворот

При *повороте* мы поворачиваем изображение вдоль центральной точки. Мы могли бы поворачивать на 360° , но поскольку на практике случайные преобразования традиционно выстраивают в цепочку, диапазона $\pm 30^\circ$ достаточно в сочетании со случайными переворотами. Указанное преобразование способствует тренировке модели усваивать инвариантность к видовому порту.

Рисунок 13.13 является примером двух выстроенных в цепочку произвольных преобразований. Первое – это произвольный поворот, за которым следует произвольная обрезка по центру.



Рис. 13.13 Цепочка произвольных преобразований

Произвольный сдвиг

При *произвольном сдвиге* мы сдвигаем изображение по вертикали или горизонтали. Если сдвигать по горизонтали, то удаляются пиксели с левой либо с правой стороны и заменяются таким же числом черных пикселей (без сигнала) на противоположной стороне. Если сдвигать по вертикали, то удаляются пиксели сверху либо снизу и заменяются таким же числом черных пикселей (без сигнала) на противоположной стороне. Общее эмпирическое правило состоит в лимитировании сдвига не более чем $\pm 20\%$ от ширины/высоты изображения, чтобы предотвращать вырезание слишком большой части интересующего объекта. Указанное преобразование способствует тренировке модели усваивать трансляционную инвариантность.

Помимо четырех рассмотренных здесь методов, существует огромное число других технических приемов преобразования, которые обеспечивают инвариантность.

13.4.2 Обогащение с помощью *tf.data*

Преобразования изображений могут добавляться в конвейер `tf.data.Dataset` с помощью метода `map()`. В этом случае мы кодируем преобразование как функцию Python, которая на входе принимает изображение, а на выходе выдает преобразованное изображение. Затем мы указываем эту функцию в качестве параметра метода `map()`, который будет применять данную функцию к каждому элементу в пакете.

В следующем ниже примере мы определяем функцию `flip()`, которая для каждого изображения в наборе данных будет выполнять произвольное преобразование в виде переворота всякий раз, когда изображение извлекается в пакет. В приведенном ниже примере мы создаем конвейер `tf.data.Dataset` из кортежа NumPy тренировочных изображений и соответствующих меток, как `(x_train, y_train)`. Затем применяем функцию `flip()` к набору данных, как `dataset.map(flip)`. Поскольку каждое изображение в пакете будет кортежем изображения и метки, для функции преобразования нам нужны два параметра: `(image, label)`. Подобным же образом нам нужно вернуть соответствующий кортеж, но с заменой входного изображения преобразованным изображением: `(transform, label)`:

```
import tensorflow as tf
from tensorflow.keras.datasets import cifar10
(x_train, y_train), (x_test, y_test) = cifar10.load_data()

def flip(image, label):
    transform = tf.image.random_flip_left_right(image)
    transform = tf.image.random_flip_up_down(transform)
    return transform, label

dataset = tf.data.Dataset.from_tensor_slices((x_train, y_train))
dataset = dataset.map(flip)
```

Функция, которая выполняет преобразование изображения, принимает на входе изображение и соответствующую метку

Произвольно переворачивает входное изображение

Возвращает преобразованное изображение и соответствующую метку

Применяет функцию преобразования в виде переворота к каждой паре изображение/метка

Далее мы выстроим несколько преобразований в цепочку для `tf.data.Dataset`. В следующем ниже примере исходного кода мы добавляем вторую функцию преобразования для выполнения произвольной обрезки. Обратите внимание, что метод `tf.image.random_crop()` не является обрезкой по центру. В отличие от обрезки по центру, которая имеет произвольный размер и всегда центрирована, этот метод TensorFlow устанавливает фиксированный размер, заданный формой, но расположение обрезки на изображении является случайным. Затем мы выстраиваем два наших преобразования в цепочку, чтобы сначала выполнить произвольный переворот, а затем произвольную обрезку: `dataset.map(flip).map(crop)`.

```

def crop(image, label):
    shape = (int(image.shape[0] * 0.8), int(image.shape[1] * 0.8),
            image.shape[2])
    transform = tf.image.random_crop(image, shape)
    return transform, label

```

Функция, которая выполняет преобразование изображения и принимает на входе изображение и соответствующую метку

Выбирает размер обрезки на основе 80 % от размера изначального изображения

Произвольно обрезает входное изображение

dataset = tf.data.Dataset.from_tensor_slices((x_train, y_train))

dataset = dataset.map(flip).map(crop) ← Применяет цепочку преобразований

13.4.3 Предстержень

Модуль `TF.Keras.layers.experimental.preprocessing` предлагает несколько преобразующих слоев, которые предоставляют средства для выполнения обогащения изображений в качестве компонента предобработки в модели. Таким образом, эти операции будут выполняться на GPU (или эквиваленте), а не на CPU. Поскольку предстержень работает по принципу «подключи и играй», после завершения тренировки этот предстержневой компонент может быть отсоединен перед развертыванием модели в производство.

В TensorFlow 2.2 преобразующие слои, которые поддерживают инвариантность к трансляции, масштабированию и видовому порту, таковы:

- `CenterCrop`;
- `RandomCrop`;
- `RandomRotation`;
- `RandomTranslation`;
- `RandomFlip`.

В следующем ниже примере мы объединяем два преобразующих слоя для обеспечения инвариантности в качестве предстержня «подключи и играй»: `RandomFlip()` и `RandomTranslation()`. Мы создаем пустую оберточную модель (`wrapper`), добавляем предстержень «подключи и играй», а затем добавляем модель. В случае развертывания мы отсоединяем предстержень «подключи и играй», как было продемонстрировано ранее в этой главе.

```

wrapper = Sequential()
wrapper.add(RandomFlip())
wrapper.add(RandomTranslation(fill_mode='constant', height_factor=0.2,
                             width_factor=0.2))
wrapper.add(model)

```

Создает оберточную модель

Добавляет инвариантный предстержень

Добавляет опорную модель

Резюме

- Базовыми компонентами конвейера данных являются хранение, извлечение, предобработка и подача данных.
- Для наилучшей производительности ввода-вывода во время тренировки следует использовать подачу данных, находящихся в памяти, если весь набор данных может поместиться в памяти; в противном случае следует использовать подачу данных с диска.
- Существуют дополнительные компромиссы между производительностью по пространству и времени в зависимости от хранения данных на диске в сжатом или несжатом виде. Возможно, вам удастся сбалансировать компромиссы, используя гибридный подход, основанный на подпопуляционном выборочном распределении.
- Если вы работаете со спутниковыми данными, то вам необходимо знать формат HDF5. Если вы работаете с данными медицинской визуализации, то вам необходимо знать формат DICOM.
- Первостепенное предназначение обогащения изображений состоит в тренировке модели усваивать трансляционную, масштабную и видовую инвариантность, чтобы обеспечить ее способностью лучше обобщать примеры, которые не встречались во время тренировки.
- Конвейер данных может быть построен выше по потоку от модели с помощью `tf.data` или TFX.
- Конвейер данных может быть построен ниже по потоку в модели с помощью преобразующих слоев `TF.Keras` подклассирования.
- Предстержень может быть сконструирован как преобразующий компонент, работающий по принципу «подключи и играй», и оставаться прикрепленным во время тренировки и обслуживания производственных запросов.
- Предстержень может быть сконструирован как обогащение, работающее по принципу «подключи и играй», прикреплен во время тренировки и отсоединен во время предсказательного вывода.

14

Конвейер тренировки и развертывания

Эта глава охватывает следующие ниже темы:

- подача тренировочных данных в модели в производстве;
- планирование непрерывной перетренировки;
- использование версионного контроля и оценивания моделей до и после их развертывания;
- развертывание моделей для крупномасштабных запросов по требованию и пакетных запросов как в монолитных, так и в распределенных развертываниях.

В предыдущей главе мы рассмотрели часть сквозного производственного конвейера машинного обучения, именуемую конвейером данных. Здесь, в заключительной главе книги, мы рассмотрим заключительную часть сквозного конвейера: тренировку, развертывание и обслуживание производственных запросов.

В целях наглядного напоминания на рис. 14.1 показан весь конвейер, заимствованный из главы 13. Я обвел кружком ту часть системы, которую мы рассмотрим в данной главе.

Вы, возможно, спросите, что, собственно говоря, представляет собой конвейер и почему мы его используем, будь то для производственной среды машинного обучения либо любой программной производственной операции, управляемой оркестровкой. Конвейеры традиционно используются, когда задание, такое как тренировка или другие операции, выполняемые с помощью оркестровки, состоит из нескольких шагов, которые выполняются в последовательном порядке: выполнить шаг А, выполнить шаг В и т. д.



Рис. 14.1 Сквозной производственный конвейер с акцентом в этой главе на тренировке и развертывании

Размещение этих шагов в производственном конвейере машинного обучения обеспечивает множество выгод. Во-первых, конвейер можно реиспользовать для последующей тренировки и развертывания. Во-вторых, конвейер можно контейнеризировать и, как таковой, исполнять как асинхронное пакетное задание. В-третьих, конвейеры можно распределять по нескольким вычислительным экземплярам, где разные задачи в конвейере исполняются на разных вычислительных экземплярах либо части одной и той же задачи исполняются в параллельном режиме на разных вычислительных экземплярах. Наконец, все задачи, ассоциированные с исполнением конвейера, можно отслеживать, а статус/исход сберегать в качестве истории.

Эта глава начинается с процедур подачи данных в модели для их тренировки в производственной среде, включая как последовательные, так и распределенные системы, а также примеры имплементаций с использованием `tf.data` и платформы TensorFlow Extended (TFX). Затем мы узнаем, как планировать тренировку и выделять вычислительные ресурсы. Мы начнем с описания реиспользуемых конвейеров, способов применения метаданных с целью интегрирования конвейеров в производственную среду вместе с историей и версионированием с целью отслеживания и аудита.

Далее посмотрим на способы оценивания моделей с целью их выпуска в производственную среду. В наши дни мы не просто сравниваем метрики из тестовых (отложенных) данных с тестовыми метриками предыдущей версии модели. Вместо этого мы выявляем разные подгруппы и распределения, которые наблюдаются в произ-

водственной среде, и создаем дополнительные оценочные данные, которые обычно называются *срезами оценивания*.

Затем модель оценивается в симулируемой производственной среде, традиционно именуемой «*песочницей*», чтобы увидеть, насколько хорошо она работает с точки зрения времени отклика и масштабирования. В данную главу включены примеры созданных в TFX имплементаций, которые оценивают кандидатную модель в симулированной производственной среде.

Далее мы перейдем к процессу развертывания моделей в производстве и обслуживанию предсказательных запросов как по требованию, так и для серийного производства. Вы найдете методы масштабирования и балансировки нагрузки в соответствии с текущим спросом на трафик. Вы также увидите, как выделяются платформы обслуживания. Наконец, мы обсудим вопрос дополнительного оценивания моделей по сравнению с предыдущей версией после их развертывания в производстве с использованием методов A/B-тестирования и последующей перетренировки на основе знаний, полученных в ходе производства с использованием методов непрерывного оценивания.

14.1 Подача данных в модель

Рисунок 14.2 представляет собой концептуальный обзор процесса подачи данных в модель в рамках конвейера тренировки. Во внешней части находится конвейер данных, который выполняет задачи по извлечению и подготовке тренировочных данных (шаг 1 на рисунке). Поскольку сегодня мы работаем в производственной среде с очень крупными объемами данных, мы будем считать, что данные извлекаются с диска по требованию. В силу этого податчик данных в модель действует как генератор и выполняет следующее:

- делает запросы к конвейеру данных на получение примеров (шаг 2);
- получает эти примеры из конвейера данных (шаг 3);
- собирает полученные примеры в пакетный формат для тренировки (шаг 4).

Податчик данных в модель передает каждый пакет методу тренировки, который последовательно подает каждый пакет (шаг 5) в модель в прямом направлении, вычисляет потерю в конце прямой подачи (шаг 6) и обновляет веса путем обратного распространения (шаг 7).

Расположенный между конвейером данных и функцией тренировки податчик данных в модель потенциально может быть в процессе тренировки бутылочным горлышком ввода-вывода, и поэтому важно продумать имплементацию, чтобы податчик данных мог генерировать пакеты так быстро, как их может потреблять метод

тренировки. Например, если податчик данных в модель работает как один поток команд CPU, а конвейер данных является мульти-CPU или GPU, и процесс тренировки является мульти-CPU, то это, скорее всего, приведет к тому, что податчик данных не сможет обрабатывать примеры так же быстро, как они поступают, либо генерировать пакеты так же быстро, как их GPU-процессоры тренировки могут их потреблять.

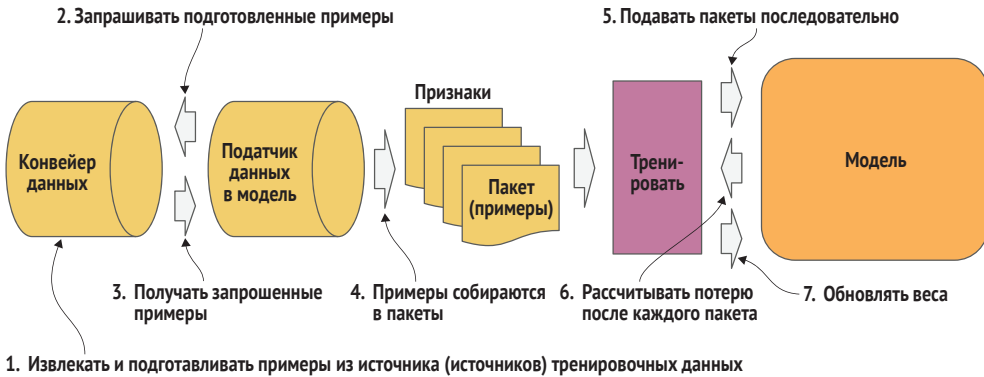


Рис. 14.2 Взаимодействие процесса подачи данных в модель между конвейером данных и методом тренировки

Учитывая его взаимосвязь с методом тренировки, податчик данных в модель должен иметь следующий пакет наготове в памяти в момент или до того, как метод тренировки потребит текущий пакет. Модельный податчик данных в производстве традиционно представляет собой многопоточный процесс, работающий на нескольких ядрах CPU. Во время тренировки тренировочные примеры подаются в модель двумя способами: последовательно и распределенно.

Податчик данных в модель для последовательной тренировки

На рис. 14.3 показан последовательный податчик данных в модель. Мы начинаем с области совместной памяти, а затем выполняем четыре шага следующим образом:

- область совместной памяти, зарезервированная для податчика данных в модель, чтобы хранить два или более пакетов в памяти (шаг 1);
- в совместной памяти имплементируется очередь «первым вошел, первым вышел» (FIFO) (шаг 1);
- первый асинхронный процесс помещает готовые пакеты в очередь (шаги 2 и 3);
- второй асинхронный процесс извлекает следующий пакет из очереди по запросу метода тренировки (шаги 3 и 4).

В целом последовательный подход является наиболее экономичным с точки зрения вычислительных ресурсов и используется, когда

период времени для завершения тренировки находится в пределах ваших требований по времени на тренировку. Его выгоды очевидны: нет вычислительных накладных расходов, как в распределенной системе, и CPU/GPU-процессоры могут работать на полную мощность.

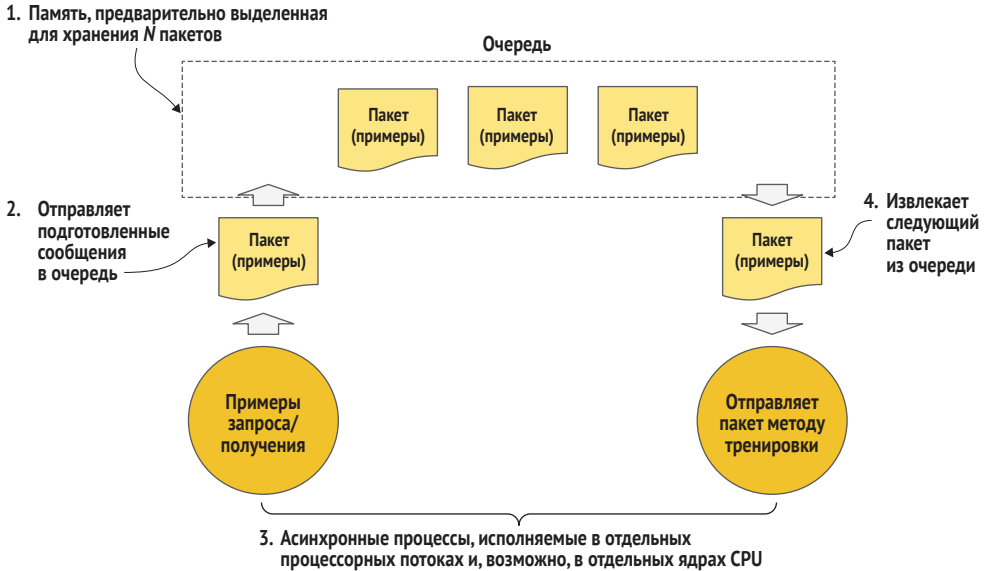


Рис. 14.3 Податчик данных в модель для последовательной тренировки

Податчик данных в модель для распределенной тренировки

В распределенной тренировке, например на нескольких GPU, влияние бутылочного горлышка ввода-вывода на податчик данных в модель может стать более серьезным. Как вы видите на рис. 14.4, он отличается от нераспределенного последовательного подхода с одним экземпляром тем, что несколько асинхронных процессов отправки извлекают пакеты из очереди, чтобы обеспечивать тренировку, подавая данные в несколько экземпляров модели в параллельном режиме.

Хотя распределенный подход будет приводить к некоторой неэффективности вычислений, он используется, когда ваши временные рамки не позволяют использовать для тренировки последовательный подход. Обычно потребность во времени зависит от деловых требований, а невыполнение деловых требований обходится дороже, чем неэффективность вычислений.

В распределенной тренировке первый асинхронный процесс должен отправлять несколько пакетов в очередь (шаг 1) со скоростью, равной или большей, чем другие множественные асинхронные процессы извлекают пакеты (шаг 2). Каждый узел распределенной тренировки имеет асинхронный процесс извлечения пакетов из очереди. Наконец, третий асинхронный процесс координирует извлечение пакетов

из очереди и ожидает завершения (шаг 3). В этой форме распределенной тренировки существует второй асинхронный процесс для каждого узла распределенной тренировки (шаг 2), где узел может быть:

- отдельными вычислительными экземплярами, соединенными в сеть;
- отдельными аппаратными ускорителями (такими как GPU) в одном и том же вычислительном экземпляре;
- отдельными процессорными потоками в многоядерном вычислительном экземпляре (таком как CPUe).

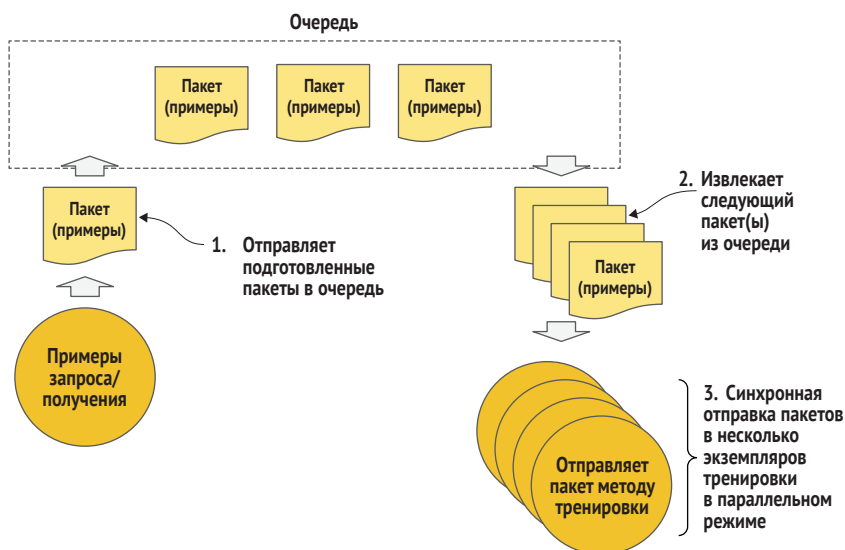


Рис. 14.4 Податчик данных в модель для распределенной тренировки

Вы, возможно, спросите: как происходит тренировка модели, когда каждый экземпляр видит только подмножество пакетов? Хороший вопрос. В этом распределенном методе мы используем пакетное сглаживание весов.

Думайте о нем так: каждый экземпляр модели усваивает информацию из подвыборочного распределения тренировочных данных, и нам нужен способ слияния весов, усвоенных из каждого подвыборочного распределения. Каждый узел по завершении пакета отправляет обновления своего веса другим узлам. Когда узлы-получатели получают весовые обновления, они усредняют их с весовыми обновлениями из своего собственного пакета – отсюда и сглаживание весов в пакете.

Существует два распространенных сетевых подхода к отправке весов. Один из них заключается в широковещательном транслировании весов на подсети, к которой подсоединены все узлы. Другой способ заключается в использовании кольцевой сети, где каждый узел отправляет свои весовые обновления следующему присоединенному узлу.

Эта форма распределенной тренировки имеет два последствия, будь то широковещательная трансляция или кольцо. Во-первых, наличие активности всей сети. Во-вторых, момент появления сообщения с весовыми обновлениями неизвестен. Она совершенно не скоординирована и не регламентирована. В результате пакетное сглаживание весов имеет присущую ему неэффективность и будет приводить к большему числу эпох, необходимых для тренировки модели, по сравнению с последовательным подходом.

ПОДАТЧИК ДАННЫХ В МОДЕЛЬ С ПОМОЩЬЮ ПАРАМЕТРИЧЕСКОГО СЕРВЕРА

В еще одной версии распределенной тренировки используется параметрический сервер. Параметрический сервер традиционно работает на еще одном узле, которым обычно является CPU. Например, в модулях TPU компании Google каждая группа из четырех TPU имеет параметрический сервер на базе CPU. Он предназначен для того, чтобы преодолевать неэффективность асинхронного обновления у пакетного сглаживания весов.

В этой форме распределенной тренировки пакетное сглаживание весовых обновлений происходит синхронно. Параметрический сервер, изображенный на рис. 14.5, рассылает разные пакеты на каждый узел тренировки, а затем ожидает до тех пор, пока каждый из них завершит потребление соответствующего пакета (шаг 1), и отправляет расчет потери обратно на параметрический сервер (шаг 2). После получения расчета потери из каждого узла тренировки параметрический сервер усредняет потерю и обновляет веса в ведущей копии, поддерживаемой параметрическим сервером, а потом отправляет обновленные веса каждому узлу тренировки (шаг 3). Затем параметрический сервер подает сигнал податчику данных, что следует разослать следующий набор параллельных пакетов (шаг 4).

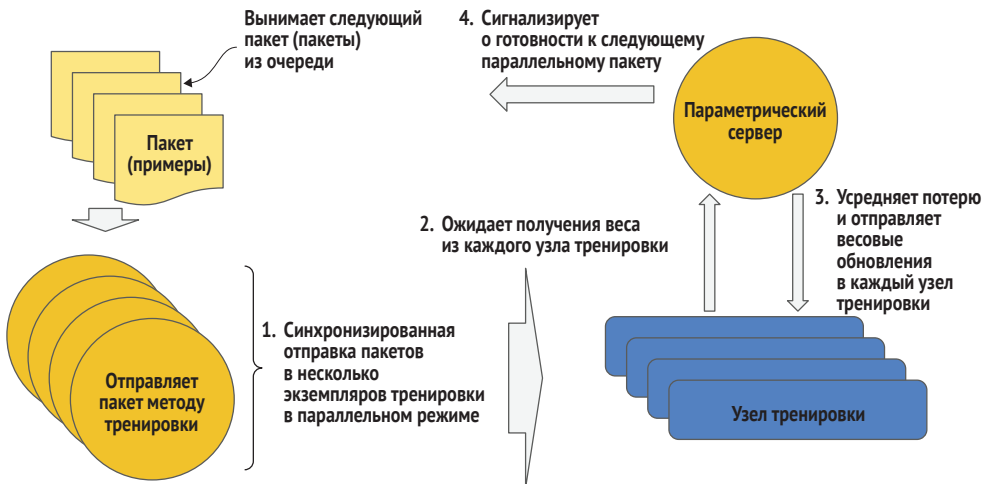


Рис. 14.5 Параметрический сервер в распределенной тренировке

Преимущество этого синхронного метода состоит в том, что на тренировку не требуется столько эпох, сколько в вышеупомянутом асинхронном методе. Но его недостатком является то, что каждый узел тренировки должен ждать на параметрическом сервере, чтобы просигнализировать о получении следующего пакета, и, таким образом, узлы тренировки могут работать ниже производительности GPU или другой вычислительной мощности.

Следует обратить внимание еще на пару вещей. В каждом раунде каждый узел распределенной тренировки получает пакет, отличающийся от другого. Поскольку между узлами тренировки имеется значительная дисперсия в потери и накладных расходах на ожидание на параметре для обновления весов, в распределенной тренировке обычно используются более крупные размеры пакетов.

Более крупные пакеты сглаживают или сокращают дисперсию между параллельными пакетами, а также уменьшают бутылочные горлышки ввода-вывода в процессе тренировки.

14.1.1 *Подача данных в модель с помощью `tf.data.Dataset`*

В главе 13 мы увидели, как `tf.data.Dataset` может использоваться для строительства конвейера данных. Его можно использовать в качестве механизма для подачи данных в модель. По сути, экземпляр `tf.data.Dataset` – это генератор. Его можно интегрировать как в последовательную, так и в распределенную тренировку. Однако в податчике-распространителе экземпляр не действует как параметрический сервер, поскольку эта функция выполняется опорной системой распространения.

Несколько главнейших выгод от `tf.data.Dataset` заключены в настройке размера пакета, перетасовке данных для рандомизированных пакетов и предварительной доставке следующих пакетов параллельно подаче текущего пакета.

Следующий ниже исходный код является примером использования `tf.data.Dataset` для подачи данных в модель во время тренировки с использованием фиктивной модели – последовательной (Sequential) модели с одним слоем (Flatten) без тренируемых параметров. Для демонстрации мы используем данные CIFAR-10 из встроенных наборов данных TF.Keras.

Поскольку данные CIFAR-10 в этом примере уже будут находиться в памяти при загрузке функцией `cifar.load_data()`, мы создадим генератор, который будет подавать пакеты из находящегося в памяти источника. Первым шагом является создание генератора для нашего находящегося в памяти набора данных. Это делается с помощью функции `from_tensor_slices()`, которая на входе принимает параметр кортежа находящихся в памяти тренировочных примеров и соответствующих меток (`x_train`, `y_train`). Обратите внимание, что указанный метод не создает копию тренировочных данных. Вместо этого он создает индекс на источник тренировочных данных и ис-

пользует этот индекс для перетасовки, прокручивания в цикле и доставки примеров:

```
from tensorflow.keras.datasets import cifar10
import numpy as np
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Flatten

(x_train, y_train), (x_test, y_test) = cifar10.load_data()
x_train = (x_train / 255.0).astype(np.float32)
x_test = (x_test / 255.0).astype(np.float32)

model = Sequential([ Flatten(input_shape=(32, 32, 3))] )
model.compile(loss='sparse_categorical_crossentropy', optimizer='adam')

dataset = tf.data.Dataset.from_tensor_slices((x_train, y_train))
dataset = dataset.batch(32).shuffle(1000).repeat().prefetch(2)

model.fit(dataset, epochs=10, steps_per_epoch=len(x_train)//32)
```

Создает `tf.data.Dataset` в качестве генератора для подачи тренировочных данных CIFAR-10 в модель

Использует генератор в качестве податчика данных в модель во время тренировки

Задаёт атрибуты подачи данных в модель

Теперь, когда в предыдущем примере исходного кода у нас есть генератор, мы добавим несколько атрибутов, чтобы завершить его в качестве податчика данных в модель:

- задаем размер пакета равным 32 (`batch(32)`);
- задаем случайную перетасовку по 1000 примеров за раз в памяти (`shuffle(1000)`);
- многократно прокручиваем все тренировочные данные (`repeat()`). Без функции `repeat()` генератор выполнит только один проход по тренировочным данным;
- параллельно с подачей пакета предварительно доставляем до двух пакетов в очереди податчика (`prefetch(2)`).

Далее этот генератор можно передать в качестве входного источника тренировочных данных команде `fit(dataset, epochs=10, steps_per_epoch=len(x_train)//32)` для тренировки. Указанная команда будет рассматривать генератор как итератор, и для каждого взаимодействия генератор будет выполнять задачу подачи данных в модель.

Поскольку для подачи данных в модель мы используем генератор, а функция `repeat()` будет приводить к тому, что генератор будет повторяться вечно, метод `fit()` не знает, когда он потребит все тренировочные данные, приходящиеся на эпоху. Поэтому нам нужно сообщить методу `fit()` число приходящихся на эпоху пакетов, которое мы задаем с помощью именованного параметра `steps_per_epoch`.

ДИНАМИЧЕСКОЕ ОБНОВЛЕНИЕ РАЗМЕРА ПАКЕТА

В главе 10 мы коснулись вопроса обратной пропорциональности размера пакета скорости усвоения. Во время тренировки эта обратная

взаимосвязь означает, что традиционные приемы подачи данных в модель будут увеличивать пакет пропорционально снижению скорости усвоения. Хотя TF.Keras имеет встроенный метод динамического обновления скорости усвоения с помощью обратного вызова планировщика `LearningRateScheduler`, в настоящее время он не обладает такой же способностью для размера пакета. Вместо этого я покажу вам самодельную версию динамического обновления размера пакета во время тренировки при одновременном снижении скорости усвоения.

Я объясню этот самодельный процесс, когда буду описывать исходный код, который его имплементирует. В данном случае в целях динамического обновления размера пакета мы добавляем внешний цикл тренировки. Вспомните, что в методе `fit()` размер пакета указывается в качестве параметра. И поэтому в целях обновления размера пакета мы будем подразделять на эпохи и вызывать функцию `fit()` несколько раз. Внутри цикла мы тренируем модель в течение определенного числа эпох. Что же касается самого цикла, то всякий раз, когда мы его выполняем, мы будем обновлять скорость усвоения и размер пакета, а также устанавливать число эпох, в течение которых следует выполнять тренировку в цикле. В цикле `for` мы используем список кортежей, и каждый кортеж будет задавать скорость усвоения (`lr`), размер пакета (`bs`) и число эпох (`epochs`), например `(0.01, 32, 10)`.

Сброс числа эпох в цикле делается просто, так как его можно указывать в качестве параметра метода `fit()`. А вот скорость усвоения мы сбрасываем путем (пере)компиляции модели и когда задаем параметр с оптимизатором – `Adam(lr=lr)`. Перекомпилировать модель можно в середине тренировки, так как это не влияет на модельные веса. Другими словами, перекомпиляция не отменяет предыдущую тренировку.

Сброс размера пакета для `tf.data.Dataset` делается не так просто, поскольку после того, как он задан, его невозможно сбросить. Вместо этого на каждой итерации цикла придется создавать новый генератор для тренировочных данных, где мы будем указывать текущий размер пакета с помощью метода `batch()`.

```
from tensorflow.keras.datasets import cifar10
import numpy as np
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Flatten, Dense, Conv2D, MaxPooling2D
from tensorflow.keras.optimizers import Adam

(x_train, y_train), (x_test, y_test) = cifar10.load_data()
x_train = (x_train / 255.0).astype(np.float32)
x_test = (x_test / 255.0).astype(np.float32)

model = Sequential([ Conv2D(16, (3, 3), activation='relu',
                           input_shape=(32, 32, 3)),
                    Conv2D(32, (3, 3), strides=(2, 2), activation='relu'),
```


<p>Создает новый генератор для сброса размера пакета</p>	<pre>MaxPooling2D((2, 2), strides=2), Flatten(), Dense(10, activation='softmax')])</pre>	<p>Внешний цикл для динамического сбрасывания гиперпараметров во время тренировки</p>
<pre>for lr, bs, epochs in [(0.01, 32, 10), (0.005, 64, 10), (0.0025, 128, 10)]: print("hyperparams: lr", lr, "bs", bs, "epochs", epochs) dataset = tf.data.Dataset.from_tensor_slices((x_train, y_train)) dataset = dataset.shuffle(1000).repeat().batch(bs).prefetch(2)</pre>		
<p>Тренирует модель с заданным числом эпох</p>	<pre>model.compile(loss='sparse_categorical_crossentropy', optimizer=Adam(lr=lr), metrics=['acc'])</pre>	<p>Перекомпилирует модель для сброса скорости усвоения</p>
<pre>model.fit(dataset, epochs=epochs, steps_per_epoch=200, verbose=1)</pre>		

Давайте взглянем на сокращенный результат выполнения нашей самодельной версии динамического сброса гиперпараметров во время тренировки. Хорошо видно, что на первой итерации внешнего цикла тренировочная точность в 10-ю эпоху составляет 51 %. На второй итерации, когда скорость усвоения уменьшается вдвое, а размер пакета увеличивается вдвое, точность усвоения в 10-ю эпоху составляет 58 %, а на третьей итерации достигает 61 %. Как видно из выходных данных, мы смогли обеспечить неуклонное снижение потери и повышение точности в течение трех итераций, по мере того как сужали пространство потери.

```
hyperparams: lr 0.01 bs 32 epochs 10
Epoch 1/10
200/200 [=====] - 1s 3ms/step - loss: 1.9392 - acc: 0.2973
Epoch 2/10
200/200 [=====] - 1s 3ms/step - loss: 1.6730 - acc: 0.4130
...
Epoch 10/10
200/200 [=====] - 1s 3ms/step - loss: 1.3809 - acc: 0.5170

hyperparams: lr 0.005 bs 64 epochs 10
Epoch 1/10
200/200 [=====] - 1s 3ms/step - loss: 1.2248 - acc: 0.5704
Epoch 2/10
200/200 [=====] - 1s 3ms/step - loss: 1.2740 - acc: 0.5510
...
Epoch 10/10
200/200 [=====] - 1s 3ms/step - loss: 1.1876 - acc: 0.5853

hyperparams: lr 0.0025 bs 128 epochs 10
Epoch 1/10
200/200 [=====] - 1s 4ms/step - loss: 1.1186 - acc: 0.6063
Epoch 2/10
200/200 [=====] - 1s 3ms/step - loss: 1.1434 - acc: 0.5997
...
Epoch 10/10
200/200 [=====] - 1s 3ms/step - loss: 1.1156 - acc: 0.6129
```

14.1.2 Распределенная подача с помощью `tf.Strategy`

Модуль TensorFlow `tf.distribute.Strategy` предлагает удобный и инкапсулированный интерфейс, в котором все сделано за вас для распределенной тренировки между несколькими GPU на одном вычислительном экземпляре или между несколькими TPU. В нем имплементирован синхронный параметрический сервер, как описано ранее в этой главе. Указанный модуль TensorFlow оптимизирован под распределенную тренировку моделей TensorFlow, а также под распределенную тренировку на параллельных TPU-процессорах Google.

Во время тренировки на одном вычислительном экземпляре с несколькими GPU используется стратегия `tf.distribute.MirroredStrategy`, а во время тренировки на TPU-процессорах применяется стратегия `tf.distribute.TPUStrategy`. В этой главе распределенная тренировка между машинами не рассматривается, за исключением того, что вы будете использовать стратегию `tf.distribute.experimental.ParameterServerStrategy`, в которой имплементирован асинхронный параметрический сервер сети. Настройка распределенной тренировки на нескольких машинах несколько сложна, и для изложения этой темы потребовалась бы отдельная глава. Я рекомендую использовать этот подход, а также изучить документацию по TensorFlow, если вы строите модели TensorFlow и удовлетворение ваших деловых задач требует значительного или масштабного параллелизма во время тренировки.

Ниже приведен наш подход к настройке прогона распределенной тренировки на одной машине с несколькими CPU или GPU:

- 1 Инстанцировать стратегию распределения.
- 2 В рамках стратегии распределения:
 - создать модель;
 - скомпилировать модель.
- 3 Натренировать модель.

Эти шаги могут показаться нелогичными, поскольку мы настраиваем стратегию распределения во время строительства и компиляции модели, а не во время ее тренировки. В TensorFlow требуется, чтобы при строительстве модели было известно, что она будет тренироваться с использованием стратегии распределенной тренировки. На момент написания этой главы коллектив разработчиков TensorFlow недавно выпустил более новую экспериментальную версию, в которой стратегия распределения может задаваться независимо от компиляции модели.

Ниже приведен исходный код с имплементацией указанных выше трех шагов и двух подшагов, которые описываются следующим образом.

- 1 Определяем функцию `create_model()` для создания экземпляра тренируемой модели.
- 2 Инстанцируем стратегию распределения: `strategy = tf.distribute.MirroredStrategy()`.

- 3 Задаем контекст распределения: `with strategy.scope()`.
- 4 Внутри контекста распределения создаем экземпляр модели: `model = create_model()`. Затем его компилируем: `model.compile()`.
- 5 Наконец, тренируем модель.

```
def create_model():  ← Функция для создания экземпляра модели
    model = Sequential([ Conv2D(16, (3, 3), activation='relu',
                             input_shape=(32, 32, 3)),
                        Conv2D(32, (3, 3), strides=(2, 2),
                             activation='relu'),
                        MaxPooling2D((2, 2), strides=2),
                        Flatten(),
                        Dense(10, activation='softmax')
                    ])
    return model

← Инстанцирует
стратегию
распределения → strategy = tf.distribute.MirroredStrategy()

with strategy.scope():  ← В рамках стратегии распределения создает
                        и компилирует модель
    model = create_model()
    model.compile(loss='sparse_categorical_crossentropy', optimizer='adam')

model.fit(dataset, epochs=10, steps_per_epoch=200)  ← Тренирует модель
```

Вы, возможно, спросите, можно ли использовать уже построенную модель? Ответ отрицательный; вы должны построить модель в рамках стратегии распределения. Например, следующий ниже исходный код вызовет ошибку, сообщаящую о том, что модель не была создана в рамках стратегии распределения:

```
model = create_model()  ← Модель не построена в рамках
with strategy.scope():  стратегии распределения
    model.compile(loss='sparse_categorical_crossentropy', optimizer='adam')
```

Опять же, вы, возможно, спросите: при наличии предварительно построенной или предварительно натренированной модели, которая не была построена в рамках стратегии распределения, можно ли все же проводить распределенную тренировку? Здесь ответом будет «да». Если у вас есть существующая сохраненная на диске модель TF.Keras, то при ее загрузке обратно в память с помощью функции `load_model()` она неявно строит модель. Ниже приведен пример имплементации настройки стратегии распределения на основе предварительно натренированной модели:

```
with strategy.scope():
    model = tf.keras.models.load_model('my_model')  ← Модель перестраивается в неявной
    model.compile(loss='sparse_categorical_crossentropy', optimizer='adam')  форме при загрузке с диска
```

И точно так же, когда предварительно построенная модель загружается из репозитория моделей, происходит неявная загрузка

и, соответственно, неявное строительство модели. Следующая ниже последовательность исходного кода является примером загрузки модели из встроенного хранилища моделей `tf.keras.applications`, где модель неявно перестраивается:

```
with strategy.scope():
    model = tf.keras.applications.ResNet50()
    model.compile(loss='sparse_categorical_crossentropy', optimizer='adam')
```

Модель неявно перестраивается
при загрузке из репозитория

По умолчанию зеркальная стратегия будет использовать все GPU на вычислительном экземпляре. С помощью свойства `num_replicas_in_sync` можно получать число используемых ядер GPU или CPU. Кроме того, можно явно указывать GPU-процессоры или ядра, которые следует использовать. В следующем ниже примере исходного кода мы настроили стратегию распределения на применение двух GPU:

```
strategy = tf.distribute.MirroredStrategy(['/gpu:0', '/gpu:1'])
print("GPU-процессоры:", strategy.num_replicas_in_sync)
```

Приведенный выше пример исходного кода генерирует следующий результат:

```
INFO:tensorflow:Using MirroredStrategy with devices
  ('/job:localhost/replica:0/task:0/device:GPU:0',
   '/job:localhost/replica:0/task:0/device:GPU:1')
GPUs: 2
```

14.1.3 Поддача данных в модель с помощью TFX

В главе 13 описан конвейер данных как часть сквозного производственного конвейера TFX. В этом разделе в качестве альтернативной имплементации рассматривается соответствующий аспект компонентов TFX конвейера тренировки, связанный с подачей данных в модель. На рис. 14.6 изображены компоненты конвейера тренировки и их взаимосвязи с конвейером данных.

Конвейер тренировки состоит из следующих компонентов:

- *тренера* – тренирует модель;
- *настройщика* – настраивает гиперпараметры (например, скорость усвоения);
- *оценщика* – оценивает целевой критерий (критерии) модели, такой как точность, и сравнивает результаты с базовым уровнем (например, с предыдущей версией);
- *инфравалидатора* – тестирует модель в симулированной производственной среде обслуживания запросов перед развертыванием.

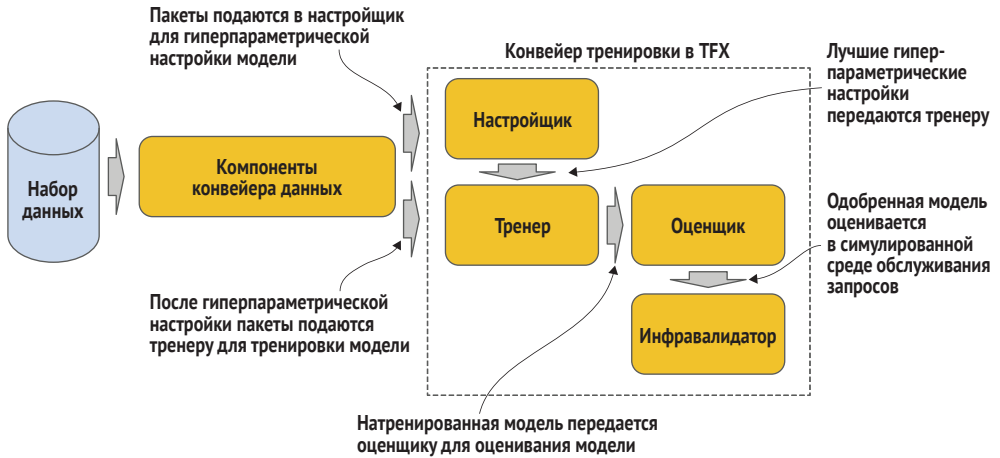


Рис. 14.6 Компоненты TFX, составляющие конвейер тренировки, состоят из следующих компонентов: настройщика, тренера, оценщика и инфравалидатора

ОРКЕСТРОВКА

Давайте проведем ревизию выгод от TFX и конвейеров в целом. Если исполнять каждый шаг в тренировке/развертывании модели индивидуально, то это называется *архитектурой с осведомленностью о задаче*. Каждый компонент знает о себе, но не знает о соединении компонентов или об истории предыдущего исполнения.

TFX имплементирует *оркестровку*. В оркестровке управляющий интерфейс контролирует исполнение каждого компонента, запоминает исполнение прошлых компонентов и ведет историю. Как ранее рассматривалось в главе 13, данные на выходе из каждого компонента являются артефактами; это результаты и история исполнения. В оркестровке эти артефакты или ссылки на них хранятся в виде метаданных. В случае TFX метаданные хранятся в реляционном формате и, следовательно, могут храниться и доступны через базу данных SQL.

Давайте копнем поглубже в преимущества оркестровки, а затем рассмотрим принцип работы подачи данных в модель в TFX. С помощью оркестровки, которая изображена на рис. 14.7, можно делать следующее:

- планировать исполнение компонента после завершения других компонентов. Например, можно запланировать исполнение преобразований данных после завершения генерирования схемы признаков из тренировочных данных;
- планировать параллельное исполнение компонентов, когда исполнение компонентов не зависит друг от друга. Например, можно запланировать параллельную гиперпараметрическую настройку и тренировку после завершения преобразований данных;

- реиспользовать артефакты предыдущего исполнения компонента (кеш), если ничего не изменилось. Например, если тренировочные данные не изменились, то кешированные артефакты (то есть граф-трансформант) из преобразовательного компонента могут реиспользоваться без повторного исполнения;
- выделять разные экземпляры вычислительных механизмов для каждого компонента. Например, компоненты конвейера данных могут выделяться на вычислительном экземпляре CPU, а тренировочный компонент – на вычислительном экземпляре GPU;
- если задача поддерживает распределение, такое как настройка и тренировка, то указанная задача может быть распределена между несколькими вычислительными экземплярами;
- сравнивать артефакты компонента с предыдущими артефактами из предыдущих исполнений компонента. Например, оценочный компонент может сравнивать целевой критерий модели (например, точность) с ранее натренированными версиями модели;
- отлаживать и аудировать исполнение конвейера, имея возможность перемещаться вперед и назад по сгенерированным артефактам.

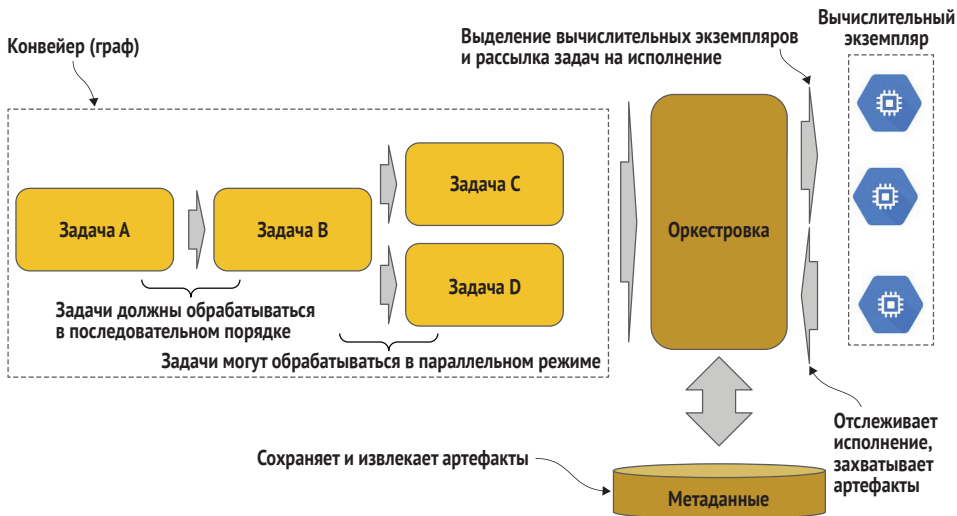


Рис. 14.7 Оркестровка вбирает в себя конвейер, представленный в виде графа, выделяет экземпляры и рассылает задачи

ТРЕНЕРСКИЙ КОМПОНЕНТ

Компонент `Trainer` поддерживает оценщиков тренировки TensorFlow, модели TF.Keras и другие циклы конкретно-прикладной тренировки. Поскольку TensorFlow 2.x рекомендует постепенно отказываться от

оценщиков, мы сосредоточимся только на конфигурировании тренерского компонента для моделей TF.Keras и подаче в него данных. Тренерский компонент принимает следующие ниже минимальные параметры:

- `module_file` – это скрипт Python для конкретно-прикладной тренировки модели. В целях выполнения тренировки он должен содержать в качестве точки входа функцию `run_fn()`;
- `examples` – примеры для тренировки модели, которые берутся из данных на выходе из компонента `ExampleGen`, то есть `example_gen.outputs['examples']`;
- `schema` – схема набора данных, которая берется из данных на выходе из компонента `SchemaGen`, то есть `schema_gen['schema']`;
- `custom_executor_spec` – исполнитель конкретно-прикладной тренировки, который будет вызывать функцию `run_fn()` в файле `module_file`.

```
from tfx.components import Trainer
from tfx.components.base import executor_spec
from tfx.components.trainer import GenericExecutor
```

Импорты для конкретно-прикладной тренировки

Конкретно-прикладной скрипт на Python

Схема, выведенная из набора данных

```
trainer = Trainer(
    module_file=module_file,
    examples=example_gen.outputs['examples'],
    schema=schema_gen.outputs['schema'],
    custom_executor_spec=executor_spec.ExecutorClassSpec(GenericExecutor)
)
```

Источник тренировочных данных для подачи в модель во время тренировки

Конкретно-прикладной исполнитель для конкретно-прикладной тренировки

Если тренировочные данные должны преобразовываться компонентом `Transform`, то необходимо установить следующие два параметра:

- `transformed_examples` – равен данным на выходе из компонента `Transform`, то есть `transform.outputs['transformed_examples']`;
- `transform_graph` – статический граф преобразований, сгенерированный компонентом `Transform`, то есть `transform.outputs['transformed_graph']`.

```
trainer = Trainer(
    module_file=module_file,
    transformed_examples=transform.outputs['transformed_examples'],
    transform_graph=transform.outputs['transform_graph'],
    schema=schema_gen.outputs['schema'],
    custom_executor_spec=executor_spec.ExecutorClassSpec(GenericExecutor)
)
```

Тренировочные данные подаются из компонента `Transform` в статический граф преобразований

Обычно мы хотим передавать в модуль тренировки другие гиперпараметры. Они могут передаваться компоненту `Trainer` в качестве дополнительных параметров `train_args` и `eval_args`. Эти параметры задаются в виде списка пар ключ/значение, конвертированных

в формат protobuf Google. Следующий ниже исходный код передает число шагов тренировки и оценивания:

```
from tfx.proto import trainer_pb2
trainer = Trainer(
    module_file=module_file,
    transformed_examples=transform.outputs['transformed_examples'],
    transform_graph=transform.outputs['transform_graph'],
    schema=schema_gen.outputs['schema'],
    custom_executor_spec=executor_spec.ExecutorClassSpec(GenericExecutor),
    train_args=trainer_pb2.TrainArgs(num_steps=10000),
    eval_args=trainer_pb2.EvalArgs(num_steps=5000)
)
```

← Импорты для формата protobuf TFX с целью передачи гиперпараметров

Гиперпараметры переданы в компонент Trainer в виде сообщений protobuf

Теперь давайте рассмотрим базовые требования к функции `run_fn()` в конкретном прикладном скрипте Python. Аргументы функции `run_fn()` создаются из параметров, переданных в компонент `Trainer`, и доступны как свойства. В следующем ниже примере имплементации мы делаем вот что:

- извлекаем суммарное число шагов тренировки: `training_args.train_steps`;
- извлекаем число шагов валидации после каждой эпохи: `training_args.eval_steps`;
- получаем пути к файлам `TFRecord` с тренировочными и оценочными данными: `training_args.train_files`. Обратите внимание, что `ExampleGen` подает `tf.Examples` не из памяти, а из находящихся на диске записей `TFRecord`, содержащих `tf.Examples`;
- получаем граф преобразований, `training_args.transform_output`, и строим функцию исполнения преобразований, `tft.TFTransformOutput()`;
- вызываем внутреннюю функцию `_input_fn()`, чтобы создать итераторы для тренировочного и валидационного наборов данных;
- строим либо загружаем модель `TF.Keras` с помощью внутренней функции `_build_model()`;
- тренируем модель с помощью метода `fit()`;
- получаем каталог обслуживания для хранения тренированной модели, `training_args.output`, который опционально задается в качестве параметра `output` для компонента `Trainer`;
- сохраняем натренированную модель в указанном местоположении выходных данных (`output`) обслуживания, `model.save(serving_dir)`.

```
from tfx.components.trainer.executor import TrainerFnArgs
import tensorflow_transform as tft
```

```
BATCH_SIZE = 64
STEPS_PER_EPOCH = 250
```

Гиперпараметры, заданные в качестве констант


```
def run_fn(training_args: TrainerFnArgs):
    train_steps = training_args.train_steps
    eval_steps = training_args.eval_steps

    train_files = training_args.train_files
    eval_files = training_args.eval_files

    tf_transform_output = tft.TFTransformOutput(training_args.transform_output)
    train_dataset = _input_fn(train_files, tf_transform_output, BATCH_SIZE)
    eval_dataset = _input_fn(eval_files, tf_transform_output, BATCH_SIZE)

    model = _build_model()

    epochs = train_steps // STEPS_PER_EPOCH

    model.fit(train_dataset, epochs=epochs, validation_data=eval_dataset,
              validation_steps=eval_steps)

    serving_dir = training_args.output
    model.save(serving_dir)
```

Шаги тренировки/валидации, переданные в качестве параметров компоненту Trainer

Шаги тренировки/валидации, переданные в качестве параметров компоненту Trainer

Строит либо загружает тренируемую модель

Создает итераторы по наборам данных для тренировочных и валидационных данных

Рассчитывает число эпох

Тренирует модель

Сохраняет модель в формате сохраненной модели (SavedModel) в заданный каталог обслуживания

При строительстве конкретно-прикладного тренировочного скрипта Python можно использовать целый ряд мелких деталей и различных направлений. Для получения более подробной информации и указаний мы рекомендуем ознакомиться с руководством TFX по компоненту Trainer (www.tensorflow.org/tfx/guide/trainer).

НАСТРОЕЧНЫЙ КОМПОНЕНТ

Компонент Tuner является в процессе тренировки опциональной задачей. При этом можно либо жестко «зашивать» значения гиперпараметров тренировки в конкретно-прикладном тренировочном скрипте Python, либо использовать настройщик для отыскания наилучших значений гиперпараметров.

Параметры настройщика (Tuner) очень похожи на параметры тренера (Trainer). То есть настройщик будет выполнять короткие прогоны тренировки, чтобы отыскивать наилучшие гиперпараметры. Но в отличие от тренера, который возвращает натренированную модель, данные на выходе из настройщика представляют собой настроенные гиперпараметрические значения. Традиционно различаются два параметра – `train_args` и `eval_args`. Поскольку это будут более короткие прогоны тренировки, число шагов для настройщика обычно составляет 20 % или меньше, чем при полной тренировке.

Другое требование состоит в том, чтобы конкретно-прикладной тренировочный скрипт Python, `module_file`, содержал функцию точки входа `tuner_fn()`. На практике традиционно принято иметь один тренировочный скрипт Python, который имеет функции `run_fn()` и `tuner_fn()`.

```
tuner = Tuner(
    module_file=module_file,
    transformed_examples=transform.outputs['transformed_examples'],
```

```

transform_graph=transform.outputs['transform_graph'],
schema=schema_gen.outputs['schema'],
train_args=trainer_pb2.TrainArgs(num_steps=2000),
eval_args=trainer_pb2.EvalArgs(num_steps=1000)
)

```

Число шагов для более коротких прогонов тренировки при настраивании

Далее мы обратимся к примеру имплементации функции `tuner_fn()`. Для гиперпараметрической настройки мы будем использовать `KerasTuner`, но вы можете применять любой настройщик, совместимый с вашей моделью. Мы рассматривали использование `KerasTuner` ранее в главе 10. Это отдельный от TensorFlow пакет, поэтому его необходимо установить следующим образом:

```
pip install keras-tuner
```

Как и в компоненте `Trainer`, параметры и заданные по умолчанию значения компонента `Tuner` передаются в функцию `tuner_fn()` в качестве свойств параметра `tuner_args`. Обратите внимание, что указанная функция запускается так же, как `run_fn()`, но отличается, когда мы переходим к шагу тренировки. Вместо вызова метода `fit()` и сохранения натренированной модели мы делаем следующее.

- 1 Инстанцируем `KerasTuner`:
 - используем `build_model()` в качестве гиперпараметрического модельного аргумента;
 - вызываем внутреннюю функцию `_get_hyperparameters()`, чтобы задать пространство гиперпараметрического поиска;
 - максимальное число испытаний установлено равным 6;
 - задаем целевой критерий выбора наилучших значений гиперпараметров. В данном случае речь идет о валидационной точности.
- 2 Передаем настройщик и остальные параметры тренировки экземпляру `TunerFnResult()`, который будет исполнять настройщика.
- 3 Возвращаем результаты из настроенных испытаний.

```
import kerastuner
```

```

def tuner_fn(tuner_args: FnArgs) -> TunerFnResult:
    train_steps = tuner_args.train_steps
    eval_steps = tuner_args.eval_steps

    train_files = tuner_args.train_files
    eval_files = tuner_args.eval_files

    tf_transform_output = tft.TFTransformOutput(tuner_args.transform_output)
    train_dataset = _input_fn(train_files, tf_transform_output, BATCH_SIZE)
    eval_dataset = _input_fn(eval_files, tf_transform_output, BATCH_SIZE)

    tuner = kerastuner.RandomSearch(_build_model(),
                                    max_trails=6,

```

Функция точки входа для гиперпараметрической настройки

Инстанцирует KerasTuner для случайного поиска

```

    hyperparameters=_get_hyperparameters(), ←
    objective='val_accuracy'
    )
    result = TunerFnResult(tuner=tuner,
        fit_kwargs={
            'x': train_dataset,
            'validation_data': eval_dataset,
            'steps_per_epoch': train_steps,
            'validation_steps': eval_steps
        })
    return result

```

Инстанцирует и исполняет настроенные испытания с помощью заданного экземпляра настройщика

Извлекает пространство гиперпараметрического поиска

Параметры тренировки для коротких прогонов тренировки во время тренировки

Теперь давайте посмотрим, как настроенный (Tuner) и тренерский (Trainer) компоненты соединены вместе, образуя исполняемый конвейер. В приведенном ниже примере имплементации мы вносим в экземпляр компонента Trainer единственную модификацию, добавляя опциональный параметр `hyperparameters` и подсоединяя вход к выходу из компонента Tuner. Теперь, когда мы выполняем экземпляр Trainer с помощью `context.run()`, оркестровщик будет видеть зависимость от Tuner и будет планировать его исполнение до полной тренировки с помощью компонента Trainer:

```

tuner = Tuner(
    module_file=module_file,
    transformed_examples=transform.outputs['transformed_examples'],
    transform_graph=transform.outputs['transform_graph'],
    schema=schema_gen.outputs['schema'],
    train_args=trainer_pb2.TrainArgs(num_steps=2000),
    eval_args=trainer_pb2.EvalArgs(num_steps=1000)
)

trainer = Trainer(
    module_file=module_file,
    transformed_examples=transform.outputs['transformed_examples'],
    transform_graph=transform.outputs['transform_graph'],
    schema=schema_gen.outputs['schema'],
    custom_executor_spec=executor_spec.ExecutorClassSpec(GenericExecutor),
    hyperparameters=tuner.outputs['best_hyperparameters'], ←
    train_args=trainer_pb2.TrainArgs(num_steps=10000),
    eval_args=trainer_pb2.EvalArgs(num_steps=5000)
)

context.run(trainer) ←

```

Получает настроенные гиперпараметры из компонента Tuner

Исполняет конвейер Tuner/Trainer

Как и в случае с тренером, скрипт Python гиперпараметрической настройки можно конфигурировать под свои потребности. См. руководство TFX по компоненту Tuner (www.tensorflow.org/tfx/guide/tuner).

14.2 Планировщики тренировки

В средах исследований или разработок конвейеры тренировки традиционно иницируются вручную; каждая задача в конвейере иницируется вручную, вследствие чего каждую задачу можно наблюдать и при необходимости отлаживать. Если же говорить о производстве, то там они автоматизированы; автоматизация делает исполнение конвейеров эффективнее, менее трудоемким и более масштабируемым. В этом разделе мы увидим, как работает планирование запусков заданий в производственной среде, когда большое число тренировочных заданий может ставиться в очередь для тренировки и/или модели постоянно проходят перетренировку.

Потребности производственной среды отличаются от потребностей исследований и разработок следующим образом:

- в производственной среде, где огромное число моделей может тренироваться непрерывно в параллельном режиме, объем вычислительных и сетевых операций ввода-вывода может существенно различаться;
- тренировочные задания могут иметь разные приоритеты, в том смысле, что они должны завершаться в рамках плана доставки для развертывания;
- тренировочные задания могут иметь потребности, возникающие по требованию, такие как специальное оборудование, которое может выделяться для каждого отдельного использования, например облачные экземпляры;
- продолжительность тренировочных заданий может варьироваться из-за перезапусков и гиперпараметрической настройки.

На рис. 14.8 показан планировщик заданий для сквозных производственных конвейеров, который типичен для крупномасштабной производственной среды с вышеупомянутыми потребностями. Мы используем концептуальное представление о том, что планирование заданий в производственной среде еще недостаточно поддерживается каркасами машинного обучения с открытым исходным кодом, но в разной степени поддерживается платными службами машинного обучения, такими как облачные провайдеры.

Давайте рассмотрим некоторые допущения в отношении производственной среды, как показано на рис. 14.8, типичные для среды производственного предприятия:

- нет никаких конкретно-прикладных заданий. Хотя во время разработки модели и могли иметься конкретно-прикладные (специальные) задания, как только модель запускается в производство, она тренируется и развертывается с помощью предопределенных версионно-контролируемых конвейеров;
- конвейеры имеют определенные зависимости. Например, конвейер тренировки для модели ввода изображений будет иметь зависимость, которую можно комбинировать только с конвейерами данных, специфичными для изображений;

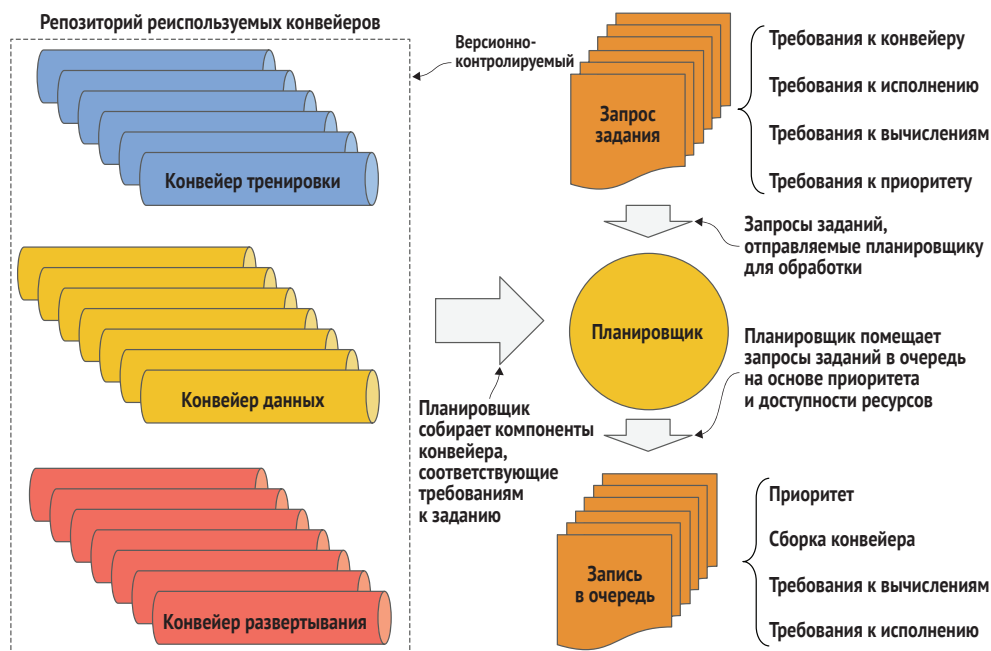


Рис. 14.8 Планирование заданий для конвейера в крупномасштабной производственной среде

- конвейеры могут иметь конфигурируемые атрибуты. Например, входную и выходную форму источника для конвейера данных можно конфигурировать;
- если выполняется обновление конвейера, то он становится следующей версией. Предыдущая версия и история исполнения оставляются;
- в запросе задания указываются требования к конвейеру. Они могут задаваться либо ссылкой на конкретные конвейеры и версии, либо атрибутами, с помощью которых планировщик определяет наиболее подходящие конвейеры. Требования могут также указывать конфигурируемые атрибуты, такие как выходная форма из конвейера данных;
- в запросе задания указываются требования к исполнению. Например, если в нем используется AutoML-подобная служба, то в нем может указываться максимальный бюджет тренировки в вычислительном времени. В еще одном примере в нем могут указываться условия ранней остановки или условия теплого старта либо перезапуска тренировочного задания;
- в запросе задания указываются требования к вычислениям. Например, в случае распределенной тренировки могут быть указано число и тип вычислительных экземпляров. Требования обычно включают требования к операционной системе и программно-информационному обеспечению;

- в запросе задания указываются требования к приоритетности. В типичной ситуации это либо исполнение по требованию, либо пакетно. Задания по требованию обычно рассылаются, когда вычислительные ресурсы доступны для выделения. Пакетные запросы традиционно откладываются до тех пор, пока не будет удовлетворено определенное условие. Например, в нем может указываться временное окно для исполнения или ожидание, когда вычислительные экземпляры будут наиболее экономными;
- в задании по требованию может дополнительно задаваться условие приоритетности. Если нет, то, как правило, оно отсылается по методу FIFO. Задания, задающие приоритет, могут изменять свое положение в рассылочной очереди FIFO. Например, задание с оценочной продолжительностью времени X и завершенное ко времени Y может быть перемещено в очереди вверх для удовлетворения указанного требования;
- как только задание отсылается из очереди, его конвейерные требования к сборке, исполнению и вычислениям передаются оркестровщику.

14.2.1 Версионирование конвейера

В производственной среде конвейер находится под версионным контролем. В дополнение к версионному контролю каждая версия конвейера будет содержать метаданные для целей отслеживания. Эти метаданные могут включать следующее:

- когда конвейер был создан и обновлен в последний раз;
- когда конвейер использовался в последний раз и с каким заданием;
- зависимости виртуальной машины (ВМ);
- среднее время исполнения;
- частота отказов.

На рис. 14.9 изображен репозиторий конвейеров данных и соответствующих реиспользуемых компонентов, находящихся под версионным контролем. В данном примере у нас два хранилища реиспользуемых компонентов:

- итераторы изображений на диске – компоненты для строительства итератора набора данных, специфичного для формата, в котором хранится набор данных;
- преобразования в памяти – компоненты для предобработки данных и преобразования с целью обеспечения инвариантности.

В этом примере мы показываем один конвейер данных в двух версиях; v2 сконфигурирована на использование стандартизации вместо перешкалирования в v1. Кроме того, история в v2 имеет более качественные результаты тренировки, чем история в v1. Конвейер данных состоит из итератора изображений на диске и реиспользуемого компонента преобразования в памяти, а также специфичного

для конвейера исходного кода. В версии v1 для нормализации данных используется перешкалирование. Допустим, позже мы обнаружим, что стандартизация дает более оптимальный результат, такой как валидационная точность, для конвейера данных во время тренировки на наборе изображений. И поэтому мы заменяем перешкалирование стандартизацией, которая создает новую версию конвейера v2.

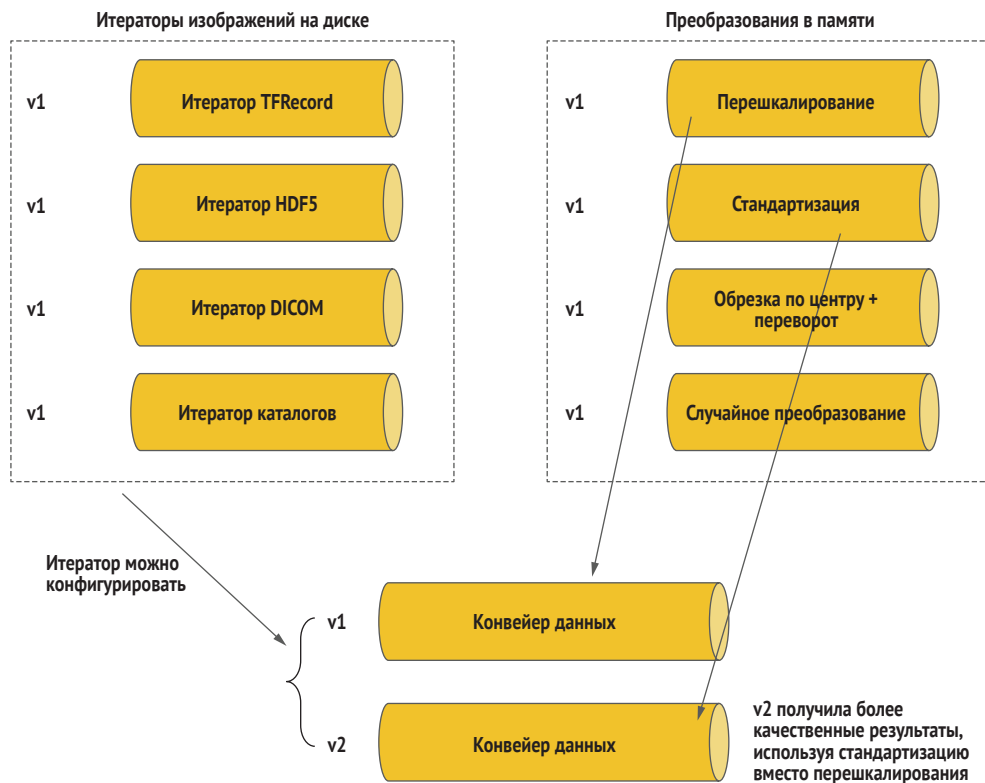


Рис. 14.9 Разные версии одного и того же конвейера данных, в которых используется другой реиспользуемый компонент преобразования в памяти

Теперь давайте рассмотрим менее очевидную систему версионного контроля (рис. 14.10). Мы продолжим наш существующий пример с конвейером данных, но на этот раз итератор находящийся на диске изображений в формате TFRecords был обновлен до версии v2, и производительность версии v2 улучшилась на 5 % по сравнению с версией v1.

Раз этот атрибут конвейера данных можно конфигурировать, тогда зачем обновлять номер версии соответствующего конвейера данных, который сам по себе не изменился? Если мы хотим воспроизвести или иным образом провести аудит тренировочного задания, в котором конвейер использовался, то нам нужно знать номер версии реиспользуемого компонента на момент выполнения задания.

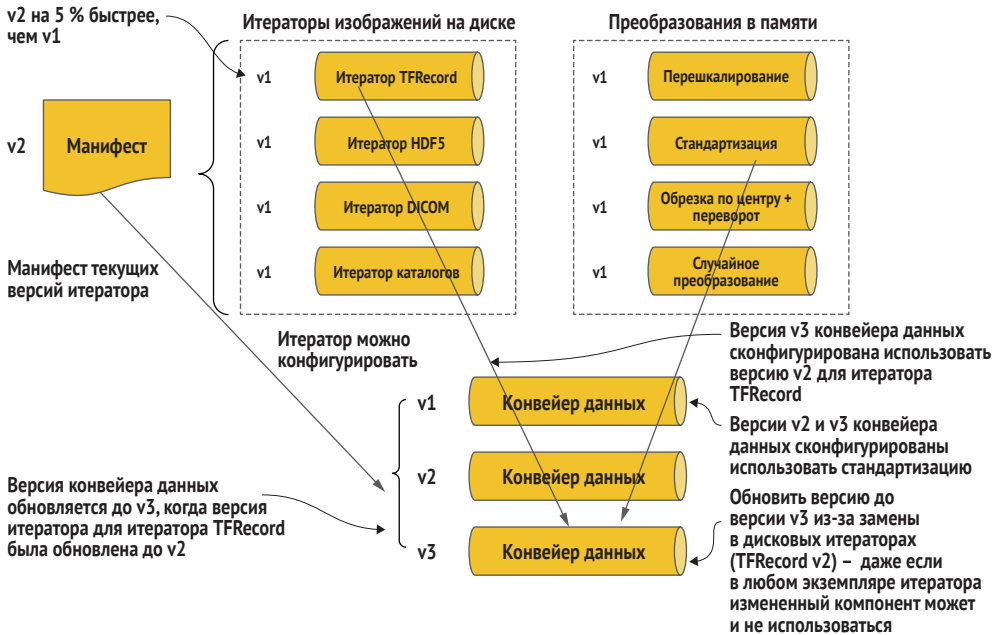


Рис. 14.10 Использование манифеста версий для идентификации версий реиспользуемых компонентов, доступных для конкретной версии конвейера

В нашем примере мы делаем это за счет:

- наличия манифеста для реиспользуемых компонентов и соответствующих номеров версий;
- обновления конвейера данных, чтобы включить обновленный манифест;
- обновления номера версии в конвейере данных.

14.2.2 Метаданные

Теперь давайте рассмотрим хранение метаданных с конвейером и другими ресурсами, такими как набор данных, и его влияние на сборку, исполнение и планирование тренировочного задания. Так что же такое метаданные и чем они отличаются от артефактов и истории? *История* всецело касается обладания информацией об исполнении конвейера, тогда как *метаданные* касаются владения информацией о состоянии конвейера. *Артефакты* представляют собой комбинацию истории и метаданных.

Обращаясь к нашему примеру конвейера данных, давайте допустим, что мы используем версию v3, но используем ее с новым ресурсом набора данных. На тот момент у нас есть одна-единственная статистика по указанному ресурсу – число примеров в наборе данных. Чего мы не знаем, так это среднего значения и стандартного отклонения примеров. Как следствие, когда конвейер данных v3 со-

бирается с новым набором данных, управляющий опорным конвейером код будет запрашивать состояние набора данных в отношении среднего значения и стандартного отклонения. Поскольку они неизвестны, управляющий конвейером код добавит компонент перед стандартизационным компонентом, чтобы рассчитать значения, необходимые для стандартизационного компонента. В верхней половине рис. 14.11 показано строительство конвейера, когда состояние среднего значения и стандартного отклонения неизвестно.

Теперь предположим, что мы снова запустим этот конвейер без каких-либо изменений в наборе данных. Будем ли мы пересчитывать среднее значение и стандартное отклонение? Нет, когда управляющий конвейером код запрашивает набор данных и обнаруживает, что значения известны, вместо этого он добавит компонент, который использует кешированные значения. В нижней половине рис. 14.11 показано строительство конвейера, когда состояние среднего значения и стандартного отклонения известно.

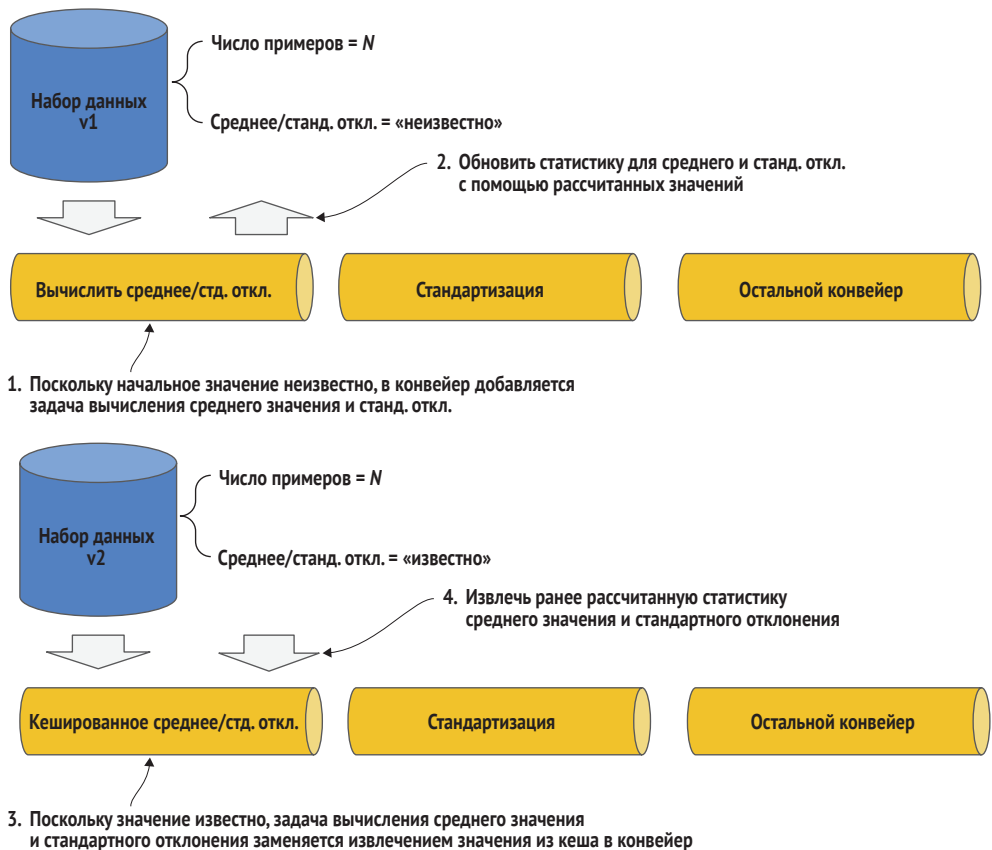


Рис. 14.11 Управляющий конвейером код, выбирающий вычисление среднего значения/стандартного отклонения либо использование значения из кеша на основе информации о состоянии из набора данных

Теперь давайте обновим набор данных, добавив несколько новых примеров, и назовем эту версию набора данных v2. Поскольку примеры были обновлены, это делает недействительным расчет предыдущего среднего значения и стандартного отклонения, поэтому обновление возвращает указанную статистику обратно к значению «неизвестно».

Так как статистика вернулась к значению «неизвестно», в следующий раз, когда версия v3 конвейера данных будет использоваться с обновленной версией v2 набора данных, управляющий конвейером код снова добавит компонент для расчета среднего значения и стандартного отклонения. На рис. 14.12 показана эта реконструкция конвейера данных.

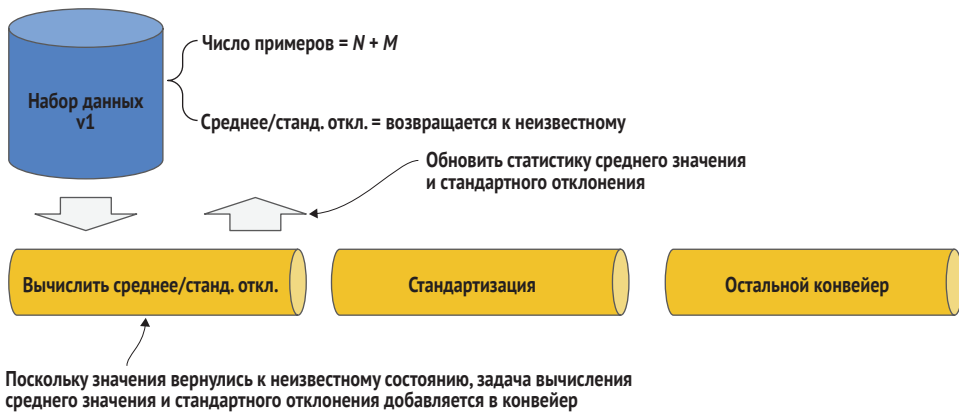


Рис. 14.12 Управляющий конвейером код добавляет пересчет среднего значения и стандартного отклонения в конвейер после добавления новых примеров в набор данных

14.2.3 История

История относится к результату исполнения экземпляра конвейера. Например, возьмем конвейер тренировки, который выполняет гиперпараметрический поиск перед полной тренировкой модели. Пространство гиперпараметрического поиска и отобранные значения из поиска становятся частью истории исполнения конвейера.

На рис. 14.13 показано исполнение экземпляра конвейера, который состоит из следующего:

- версии конвейерных компонентов, v1;
- тренировочные данные и соответствующее состояние, статистика;
- ресурс натренированной модели и соответствующее состояние, метрики;
- версия экземпляра исполнения, версия v1.1, и соответствующая история, гиперпараметры.

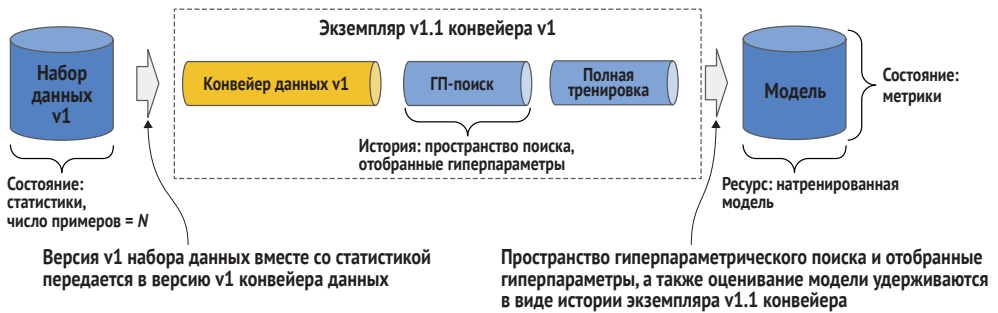


Рис. 14.13 История исполнения экземпляра конвейера, где артефактами являются состояние, история и ресурс

Хорошо, а как бы мы включили историю в последующие экземпляры исполнения одного и того же конвейера? На рис. 14.14 показана та же конфигурация конвейера, что и на рис. 14.13, но с новой версией набора данных v2. Набор данных v2 отличается от набора данных v1 включением малого числа новых примеров; это число новых примеров существенно меньше суммарного числа примеров.

В течение сборки экземпляра конвейера управляющий конвейером код может использовать историю предыдущего экземпляра исполнения. В нашем примере число новых примеров достаточно невелико, чтобы управляющий конвейером код реиспользовал отобранные значения гиперпараметров из предыдущей истории исполнения, устраняя накладные расходы на повторный гиперпараметрический поиск.

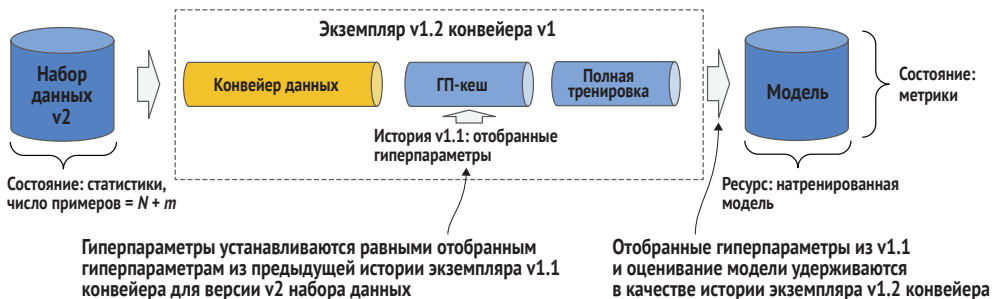


Рис. 14.14 Управляющий конвейером код, реиспользующий отобранные гиперпараметры из предыдущей истории исполнения, когда число новых примеров существенно невелико

На рис. 14.15 показан альтернативный подход к управлению конвейером в нашем примере. В этой альтернативе управляющий конвейером код продолжает конфигурировать задачу выполнения гиперпараметрического поиска во втором экземпляре исполнения, но отличается следующим образом:

- исходит из того, что новые значения гиперпараметров для второго экземпляра исполнения будут находиться вблизи отобранных значений из первого исполнения;

- сужает пространство поиска до малого эpsilon вокруг отобранных параметров из истории первого экземпляра исполнения.

Ранее мы рассмотрели часть сквозного производственного конвейера, связанного с данными и тренировкой, и планирование заданий. Следующий раздел посвящен вопросу о том, как модели оцениваются перед развертыванием в производственной среде.

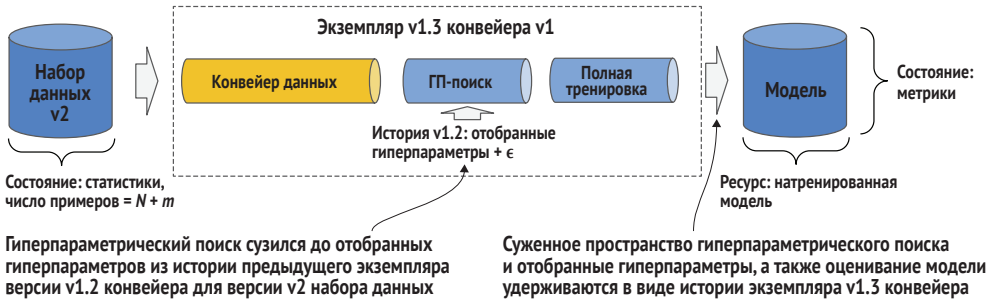


Рис. 14.15 Управление конвейером сужает пространство гиперпараметрического поиска, чтобы оно было в пределах предыдущей истории исполнения, когда число новых примеров существенно невелико

14.3 Оценивание моделей

В производственной среде оценивание модели предназначено для определения ее результативности по сравнению с базовым уровнем до развертывания в производстве. Если модель развертывается в первый раз, то базовый уровень определяется производственным коллективом, обычно именуемым группой по *операциям машинного обучения*. В противном случае базовым уровнем является развернутая в настоящее время производственная модель, обычно именуемая *одобренной моделью* (blessed model). Модель, оцениваемая по сравнению с базовым уровнем, называется *кандидатной моделью*.

14.3.1 Кандидатная модель против одобренной модели

Ранее мы рассматривали оценивание моделей в контексте экспериментов и разработок, в которых оценивание основывается на метриках тестового (отложенного) набора данных, относящихся к целевому критерию. В производстве, однако, оценивание основывается на расширенном наборе факторов, таких как потребление ресурсов, масштабирование и наборы образцов, которые одобренная модель видит в производстве (они не являются частью тестового набора данных).

Например, давайте допустим, что мы хотим оценить следующую версию производственной кандидатной модели. То есть мы хотим провести сравнение яблок с яблоками. Для этого будем оценивать

одобренную и кандидатную модели относительно одних и тех же тестовых данных, обеспечив, чтобы тестовые данные имели такое же выборочное распределение, как и набор данных, используемый для тренировки. Мы также хотим протестировать обе модели одним и тем же подмножеством производственных запросов; эти запросы должны иметь такое же выборочное распределение, которое одобренная модель фактически видела в производстве. Для того чтобы кандидатная модель заменила одобренную модель и стала следующей версией для развертывания, значения метрик (например, точность классификации) должны быть лучше как на тестовой, так и на производственной выборке. На рис. 14.16 вы видите компоновку данного теста.



Рис. 14.16 Оценивание кандидатной модели включает распределение данных как из тренировочных, так и из производственных данных

Итак, вы, возможно, спросите, почему бы нам просто не оценить кандидатную модель относительно тех же тестовых данных, что и у одобренной модели? Реальность такова, что как только модель развернута, распределение в примерах, на которых она делает предсказания, скорее всего, не будет совпадать с тем, на котором она была натренирована. Мы также хотим оценивать модель в сравнении с тем, что она, скорее всего, увидит после ее развертывания. Далее рассмотрим два типа изменений в распределении, связанных с тренировкой и производством: перекоз в обслуживании производственных запросов и дрейф данных.

ПЕРЕКОЗ В ОБСЛУЖИВАНИИ

Теперь давайте рассмотрим подробнее вопрос, почему мы оцениваем кандидатную модель относительно производственных данных. В главе 12 мы коснулись вопроса о том, как тренировка, скорее все-

го, является выборочным распределением подпопуляции, а не популяции. Сначала давайте допустим, что предсказательные запросы к развернутой модели относятся к одной и той же подпопуляции. Например, давайте допустим, что модель натренирована распознавать 10 видов фруктов и что все предсказательные запросы к развернутой модели были из одних и тех же 10 видов фруктов – одной и той же подпопуляции.

Но теперь давайте предположим, что у нас разное выборочное распределение. Встречаемая производственной моделью частота в расчете на класс отличается от тренировочных данных. Например, предположим, что тренировочные данные идеально сбалансированы, имея по 10 % примеров по каждому из 10 видов фруктов, и что совокупная точность классификации составила 97 % на тестовых данных. Но для одного из 10 классов (скажем, персиков) точность составила 75 %. Теперь предположим, что 40 % предсказательных запросов, отправленных в развернутую одобренную модель, являются персиками. В этом случае подпопуляция осталась прежней, но выборочное распределение изменилось между тренировочными данными и производственными запросами. Такая ситуация называется *перекосом в обслуживании* производственных запросов.

Так как же нам быть? Во-первых, мы должны сконфигурировать систему, которая улавливает случайную подборку предсказаний и соответствующих результатов. Допустим, вы хотите собрать 5 % всех предсказаний. Вы могли бы создать равномерное случайное распределение целых чисел от 1 до 20 и для каждого предсказания извлекать значение из распределения. Если извлеченное значение равно 1, то вы сохраняете предсказание и соответствующий результат. После выборочного периода вы затем инспектируете сохраненные предсказания/результаты в ручном режиме и определяете правильную фундаментальную истину по каждому предсказанию. Затем вы сравниваете помеченные вручную фундаментальные истины с предсказанными результатами, чтобы определить метрику на развернутой производственной модели.

Потом оцениваете кандидатную модель с помощью помеченной вручную версии той же производственной выборки.

ДРЕЙФ ДАННЫХ

Теперь давайте предположим, что производственное выборочное распределение относится не к одной и той же подпопуляции тренировочных данных, а к другой подпопуляции. Давайте продолжим наш пример с 10 видами фруктов и допустим, что тренировка состоит из свежесобранных и спелых фруктов. Но наша модель используется на сельскохозяйственных тракторах во фруктовых садах, где фрукты могут быть на разных стадиях зрелости: зеленые, спелые, гнилые. Зеленые и гнилые версии фруктов представляют собой подпопуляцию, отличную от тренировочных данных. В этом случае выборочное

распределение осталось прежним, но подпопуляции изменились между тренировочными данными и производственными запросами. Такая ситуация называется *дрейфом данных*.

В этом случае мы хотим выделить и поделить производственную выборку на раздел, относящийся к той же подпопуляции, что и тренировочные данные (например, зрелые), и раздел, относящийся к другой подпопуляции, отличающейся от той, к которой относятся тренировочные данные (например, зеленые и гнилые). Затем мы бы провели отдельное оценивание каждого раздела производственной выборки.

В совокупности тестовая выборка и выборки из перекоса в обслуживании и дрейфа данных называются *срезом оценивания*, который показан на рис. 14.17. Организация может иметь конкретно-прикладное определение срезов оценивания, специфичное для ее производства, тогда как этот набор из тестового среза и срезов перекоса в обслуживании и дрейфа данных является общим эмпирическим правилом.

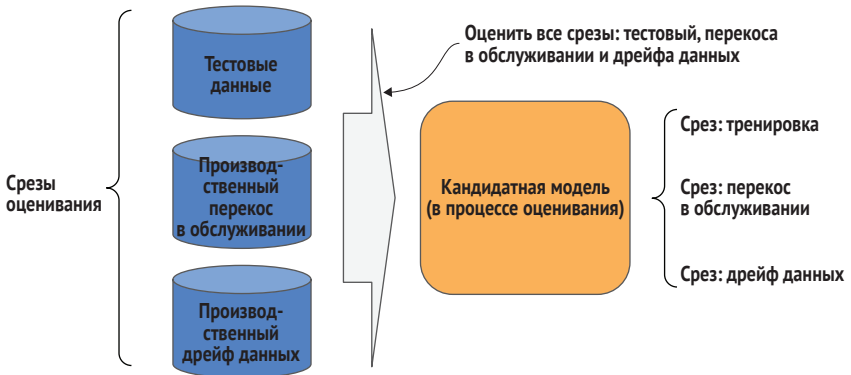


Рис. 14.17 Срезы оценивания в производстве, состоящие из выборок из тренировочных данных, перекоса в обслуживании и дрейфа данных, относящихся к производственным запросам

ИЗМЕНЕНИЕ МАСШТАБА

Теперь давайте предположим, что наша кандидатная модель, по меньшей мере, равна или лучше хотя бы на одной метрике во всех срезах оценивания из одобренной модели. Можно ли сейчас создать кандидатную версию и развернуть ее в качестве замены одобренной модели? Пока что нет. Мы еще не знаем, как кандидатная модель покажет себя в вычислительном плане по сравнению с одобренной моделью. Возможно, кандидатная модель займет больше памяти, или, вероятно, кандидатная модель будет иметь более длительную задержку.

Прежде чем принять окончательное решение, необходимо развернуть модель в симулированной производственной среде, которая

копирует вычислительную среду развернутой одобренной модели. Мы также хотим обеспечить, чтобы в течение периода оценивания предсказательные запросы в производственной среде дублировались в реальном времени и отправлялись как в производственную, так и в симулированную производственную среду. Наша цель для модели в симулированной производственной среде состоит в сборе метрик задействованности, таких как потребляемые вычислительные ресурсы и ресурсы памяти, а также времени задержки результатов предсказания. Компоновка указанной симулированной производственной среды («песочницы») показана на рис. 14.18.

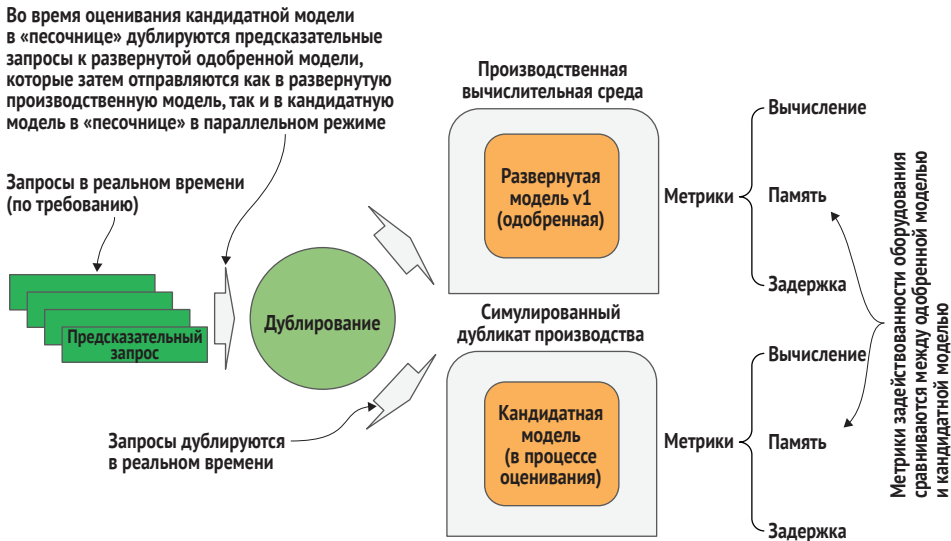


Рис. 14.18 Последним шагом перед развертыванием является выполнение кандидатной модели в симулированной производственной среде с использованием тех же предсказательных запросов, что и в одобренной модели

Вы, возможно, спросите, зачем нужно тестировать кандидатную модель в симулированной производственной среде. Мы хотим знать, что новая модель продолжает соответствовать деловым требованиям по производительности обслуживания производственных запросов. Возможно, кандидатная модель имеет существенное увеличение в операциях матричного умножения, вследствие чего время задержки при возврате предсказания больше и не соответствует деловым требованиям. Вероятно, отпечаток памяти увеличился настолько, что модель запускает постраничное кеширование памяти в условиях высоких нагрузок на обслуживание.

Теперь давайте рассмотрим несколько сценариев. Прежде всего вы, возможно, скажете, что даже если отпечаток памяти или масштаб вычислений и будет крупнее, или задержка будет больше, то можно просто добавить больше вычислительных ресурсов и/или ресурсов памяти. Однако есть много причин, по которым вы не сможете

просто добавлять больше ресурсов. Если модель развернута в ограниченной среде, такой как, например, мобильное устройство, то у вас нет возможности изменить память или вычислительное устройство. Или, вероятно, окружающая среда обладает фантастическими ресурсами, но не может быть изменена в дальнейшем, как, например, космический корабль, запущенный в космос. Или, возможно, модель используется школьным округом, у которого есть фиксированный выделенный бюджет на вычислительные затраты.

Независимо от причины необходимо выполнить окончательное оценивание масштабов с целью определения используемых ресурсов. В случае ограниченных сред, таких как мобильные телефоны или устройства интернета вещей, требуется выяснить, будет ли кандидатная модель по-прежнему соответствовать операционным требованиям развернутой модели. И если ваша среда не является ограниченной, как, например, автоматически масштабируемые экземпляры облачных вычислений, то вам необходимо знать, соответствует ли новая модель стоимостным требованиям к возвратности инвестиций (ROI).

14.3.2 Оценивание в TFX

Теперь давайте посмотрим, как использовать TFX для оценивания текущей натренированной модели, чтобы можно было решить, станет ли она следующей одобренной моделью. По сути, мы используем компоненты `Evaluator` и `InfraValidator`.

Оценщик

Компонент `Evaluator`, который выполняется после завершения компонента `Trainer`, оценивает модель относительно базового уровня. Мы подаем в оценщика оценочный набор данных из компонента `ExampleGen`, а также натренированную модель из компонента `Trainer`.

Мы также подаем в него предыдущую одобренную модель, если таковая существует. Если предыдущей одобренной модели нет, то сравнение с базовым уровнем одобренной модели пропускается.

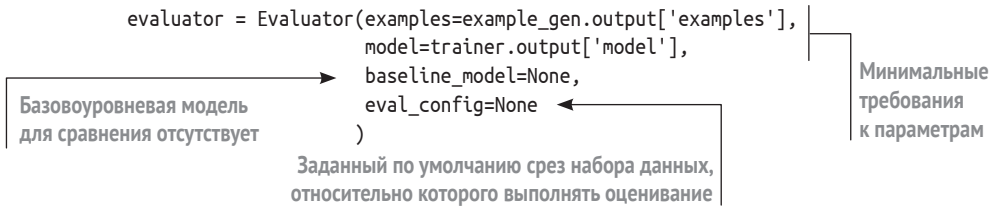
В компоненте `Evaluator` используется библиотека метрик анализа модели TensorFlow (TensorFlow Model Analysis Metrics library), которую необходимо импортировать в дополнение к TFX, как показано ниже:

```
from tfx.components import Evaluator, ResolverNode
import tensorflow_model_analysis as tfma
```

Следующий ниже пример исходного кода демонстрирует минимальные требования для встраивания компонента `Evaluator` в конвейер TFX со следующими параметрами:

- `examples` – данные на выходе из `ExampleGen`, который генерирует пакеты оцениваемых примеров;

- `model` – данные на выходе из `Trainer` оцениваемой натренированной модели.



В приведенном выше примере параметру `eval_config` задано значение `None`. В этом случае оценщик будет использовать для оценивания весь набор данных целиком, а также метрики, указанные, когда модель проходила тренировку, такие как точность для классификационной модели.

Параметр `eval_config`, если он указан, принимает экземпляр `tfma.EvalConfig`, который принимает три параметра:

- `model_specs` – спецификация данных на входе и выходе из модели. По умолчанию предполагается, что данные на входе имеют заданную по умолчанию сигнатуру обслуживания производственных запросов;
- `metrics_specs` – спецификация одной или нескольких метрик, используемых для оценивания. Если не указано, то используются метрики, указанные во время тренировки модели;
- `slicing_specs` – спецификация одного или нескольких срезов из набора данных, которые будут использоваться для оценивания. Если не указано, то используется весь набор данных целиком.

```

eval_config = tfma.EvalConfig(model_specs=[],
                              metrics_specs=[],
                              slicing_specs=[])
  
```

Параметры для `EvalConfig` сильно различаются, и я рекомендую почитать учебные пособия TensorFlow TFX по компоненту `Evaluator` (www.tensorflow.org/tfx/guide/evaluator) в целях более глубокого понимания, чем тот объем, который я здесь излагаю.

Если для сравнения имеется ранее одобренная модель, то параметру `baseline_model` задается значение экземпляра компонента TFX `ResolverNode`.

Следующий ниже пример исходного кода является минимальной спецификацией для `ResolverNode`, у которого параметры таковы:

- `instance_name` – это имя, назначаемое следующей одобренной модели, которое хранится в качестве метаданных;
- `resolver_class` – это тип экземпляра используемого резолвера. В данном случае мы указываем тип экземпляра для одобрения последней модели;

- `model` – здесь указывается тип одобряемой модели. В данном случае `Channel(type=Model)` может быть либо оценщиком TensorFlow, либо моделью TF.Keras;
- `model_blessing` – указывает, как хранить одобренную модель в метаданных.

```
from tfx.dsl.experimental.latest_blessed_model_resolver import
    LatestBlessedModelResolver
from tfx.types import Channel
from tfx.types.standard_artifacts import Model, ModelBlessing

baseline_model = ResolverNode(instance_name='blessed_model',
                               resolver_class=LatestBlessedModelResolver,
                               model=Channel(type=Model),
                               model_blessing=Channel(type=ModelBlessing)
                               )
```

Если в приведенном выше примере исходного кода экземпляр `ResolverNode()` вызывается для модели в первый раз, то текущая модель становится одобренной моделью и хранится в метаданных как одобренная модель с именем экземпляра `blessed_model`.

В противном случае текущая модель сравнивается с предыдущей одобренной моделью, которая идентифицируется как `blessed_model` и соответствующим образом извлекается из хранилища метаданных. В этом случае обе модели оцениваются относительно одних и тех же срезов оценивания, при этом сравниваются их соответствующие метрики. Если новая модель улучшает эти метрики, то она становится следующей версией экземпляра `blessed_model`.

ИНФРАВАЛИДАТОР

Следующим в конвейере является компонент `InfraValidator`. *Инфра* относится к инфраструктуре. Этот компонент вызывается только в том случае, если текущая натренированная модель становится новой одобренной моделью. Данный компонент предназначен для определения возможности загрузки модели и ее запрашивания в «песочнице», симулирующей производственную среду. Пользователь должен определить симулированную производственную среду. Другими словами, пользователь должен решить степень близости симулированной производственной среды к реальной производственной среде и, следовательно, степень точности теста *инфравалидатора*.

В следующем ниже примере исходного кода показаны минимальные требования к параметрам инфравалидатора:

- `model` – натренированная модель (в данном примере текущая натренированная модель из компонента `Trainer`);
- `serving_spec` – спецификация симулированной производственной среды.

```

from tfx.components import Evaluator, ResolverNode

infra_validator = InfraValidator(model=trainer.outputs['model'],
                                serving_spec=serving_spec)

```

Натренированная модель, которая должна быть развернута в симулированной производственной среде

Спецификация симулированной производственной среды («песочницы»)

Спецификация обслуживания производственных запросов состоит из двух частей:

- тип двоичного компонента обслуживания. Начиная с версии 0.22 TFX поддерживается только TensorFlow Serving;
- тип платформы обслуживания, которой может одна из двух:
 - Kubernetes;
 - локальный контейнер Docker.

В приведенном ниже примере показаны минимальные требования к определению спецификации обслуживания с использованием TensorFlow Serving и кластера Kubernetes:

```

from tfx.proto.infra_validator_pb2 import ServingSpec

serving_spec =
    ServingSpec(tensorflow_serving=TensorflowServing(tags=['latest']),
                kubernetes=KubernetesConfig()
    )

```

Документация TFX по ServingSpec в настоящее время скудна и будет перенаправлять вас прочитать определение protobuf (<http://mng.bz/6NqA>) в репозитории GitHub, чтобы получить дополнительную информацию.

14.4 Обслуживание предсказательных запросов

Теперь, когда у нас есть новая одобренная модель, мы обратимся к вопросу о том, как модель развертывается в производстве для обслуживания предсказательных запросов. Производственная модель обычно развертывается либо для предсказания по требованию (в реальном времени), либо для пакетного предсказания.

Чем пакетное предсказание отличается от предсказания по требованию (в реальном времени) из развернутой модели? Существует одно ключевое отличие, но в остальном в том, что касается исхода, они, по сути, одинаковы:

- *предсказание по требованию (в реальном времени)* – выполняет предсказание по требованию для всего набора экземпляров (одного или нескольких элементов данных) и возвращает результаты в реальном времени;

- *служба пакетного предсказания* – выполняет предсказание пакетно, то есть из очереди, для всего набора экземпляров в фоновом режиме и сохраняет результаты в корзине облачного хранилища, когда результаты готовы.

14.4.1 Обслуживание по требованию (в реальном времени)

В случае предсказания по требованию, такого как онлайн-запрос через интерактивный веб-сайт, модель развертывается в одном или нескольких вычислительных экземплярах и получает предсказательные запросы в виде HTTP-запросов. Предсказательный запрос может состоять из одного или нескольких отдельных предсказаний; каждое предсказание обычно называется *экземпляр*. Запросы с одним экземпляром могут быть, когда пользователь хочет классифицировать только одно изображение, а запросы с несколькими экземплярами – когда модель будет возвращать предсказания для нескольких изображений.

Допустим, модель получает запросы с одним экземпляром: пользователь отправляет изображение и хочет получить обратно предсказание, например классификацию или подпись к изображению. Все запросы осуществляются в реальном времени по запросу, которые поступают через интернет. Они могут поступать, например, из веб-приложения, запущенного в веб-браузере пользователя, либо из внутреннего приложения на сервере, получающего предсказания в виде микрослужбы.

Указанный процесс показан на рис. 14.19. На этом изображении модель содержится в двоичном компоненте обслуживания, который состоит из веб-сервера, функции обслуживания и одобренной модели. Веб-сервер получает предсказательный запрос в виде пакета HTTP-запроса, извлекает содержимое запроса и передает содержимое функции обслуживания. Затем функция обслуживания преобразовывает содержимое в формате и форме, ожидаемых входным слоем одобренной модели, которое затем передается в одобренную модель. Одобренная модель возвращает предсказания в функцию обслуживания, которая выполняет любую постобработку с целью окончательной доставки. Предсказания затем доставляются обратно на веб-сервер, а тот, в свою очередь, возвращает предобработанные предсказания в виде пакета HTTP-ответа.




Рис. 14.19 Производственная модель в двоичном компоненте обслуживания, принимающем предсказательные запросы по требованию через интернет

Как видно по рис. 14.19, один или несколько предсказательных запросов на стороне клиента передаются веб-клиенту. Затем веб-клиент создает пакет HTTP-запроса с предсказанием в одном или нескольких экземплярах. Предсказательные запросы обычно кодируются как base64, с целью обеспечения безопасной передачи через интернет и помещаются в пакет HTTP-запроса, в его раздел содержимого.

Веб-сервер получает HTTP-запрос, декодирует раздел содержимого и передает один или несколько предсказательных запросов в функцию обслуживания.

Теперь давайте рассмотрим предназначение и конструкцию функции обслуживания поглубже. Как правило, на стороне клиента содержимое (например, изображения, видео, текст и структурированные данные) отправляется в сыром формате в двоичный компонент обслуживания без какой-либо предобработки. Веб-сервер, получив запрос, извлекает содержимое из пакета запроса и передает его функции обслуживания. Содержимое может быть или не быть декодировано, например декодером base64, до момента передачи функции обслуживания.

Давайте допустим, что содержимым является запрос с одним экземпляром, состоящий из сжатого изображения, например в формате JPG или PNG. Допустим, что входным слоем модели являются несжатые байты изображения в формате многомерного массива, такого как тензор TensorFlow или массив NumPy. Как минимум функция обслуживания должна выполнять любую предобработку, которая не является частью модели (к примеру, предстержнем). Исходя из допущения, что модель не имеет предстержня, функция обслуживания должна будет выполнить следующее:

- определить сжатый формат изображения, например по типу MIME;
- разжать изображение в сырые байты;
- реформировать сырые байты в высоту × ширину × канал (например, RGB);
- изменить размер изображения в соответствии с входной формой модели;
- перешкалировать пиксельные данные с целью нормализации или стандартизации.

Далее приведен пример имплементации функции обслуживания для модели классифицирования изображений, где предобработка изображений происходит выше по потоку от модели, без предстержня. В данном примере метод `serving_fn()` регистрируется на веб-сервере в двоичном компоненте обслуживания путем назначения указанного метода в качестве сигнатуры `serving_default` для модели. Мы добавили в функцию обслуживания декоратор `@tf.function`, который инструктирует компилятор AutoGraph о необходимости конвертировать исходный код Python в статический граф, который затем можно исполнить на GPU вместе с моделью. В этом примере

предполагается, что веб-сервер передает содержимое, извлеченное из предсказательного запроса (в данном случае сжатые байты JPG), в виде строкового литерала TensorFlow. Вызов функции `tf.saved_model.save()` сохраняет функцию обслуживания в том же месте хранения, что и модель, которое задается параметром `export_path`.

Теперь давайте рассмотрим тело этой функции обслуживания. В следующем ниже примере исходного кода мы исходим из допущения, что веб-сервер в двоичном компоненте обслуживания извлекает содержимое из пакета HTTP-запроса, декодирует кодировку `base64` и передает содержимое (сжатые байты изображения JPG) в виде строкового литерала TensorFlow, `tf.string`. Затем функция обслуживания выполняет следующее:

- вызывает функцию предобработки `preprocess_fn()` для декодирования изображения JPG в сырые байты и изменения размера и перешкалирования в соответствии с входным слоем опорной модели в виде многомерного массива TensorFlow;
- передает многомерный массив TensorFlow в опорную модель, `m_call()`;
- возвращает предсказание `prob` из опорной модели обратно на веб-сервер;
- веб-сервер в двоичном компоненте обслуживания упаковывает результат предсказания в пакет HTTP-ответа обратно веб-клиенту.

Определение функции обслуживания, которая получает содержимое предсказательного запроса через веб-сервер двоичного компонента обслуживания

Метод, который конвертирует содержимое, чтобы он совпадал с входным слоем опорной модели

```
@tf.function(input_signature=[tf.TensorSpec([None], tf.string)])
def serving_fn(bytes_inputs):
    images = preprocess_fn(bytes_inputs)
    prob = m_call(**images)
    return prob
```

Предобработанные данные передаются в опорную модель для выполнения предсказания

```
tf.saved_model.save(model, export_path, signatures={
    'serving_default': serving_fn,
})
```

Результат предсказания возвращается на веб-сервер двоичного компонента обслуживания, чтобы его вернуть в качестве HTTP-ответа

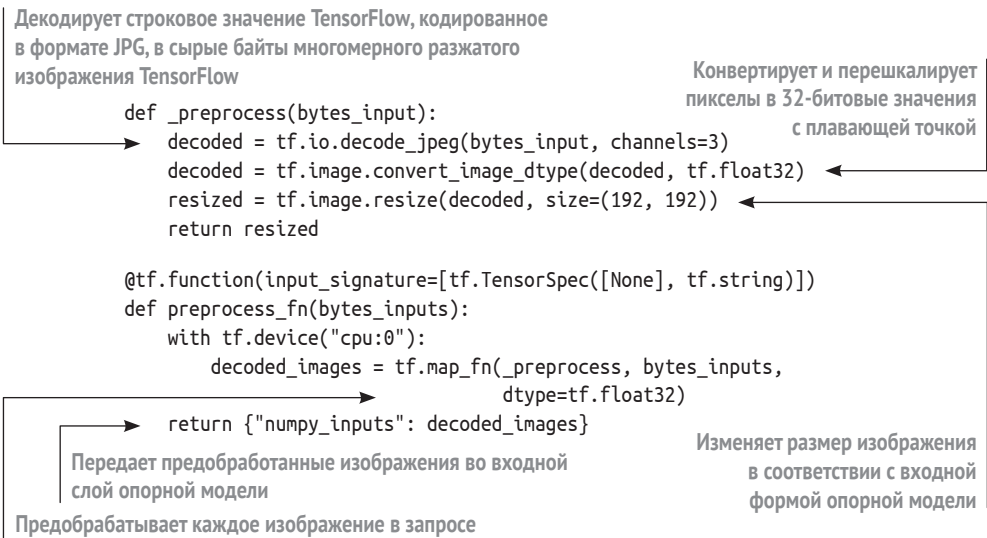
Сохраняет функцию обслуживания в качестве статического графа вместе с опорной моделью

Ниже приведен пример имплементации предобрабатывающего шага функции обслуживания. В данном примере функция `preprocess_fn()` принимает на входе декодированное в формат `base64` строковое значение TensorFlow с веб-сервера и выполняет следующее:

- вызывает операцию статического графа TensorFlow `tf.io.decode_jpeg()`, чтобы декодировать входные данные в разжатое изображение в виде многомерного массива TensorFlow;
- вызывает операцию статического графа TensorFlow `tf.image.convert_image_dtype()`, чтобы конвертировать целочисленные

пиксельные значения в 32-битовые значения с плавающей точкой и перешкалировать значения в диапазон от 0 до 1 (нормализация);

- вызывает операцию статического графа TensorFlow `tf.image.resize()`, чтобы изменить размер изображения в соответствии с входной формой модели. В этом примере она будет равна (192, 192, 3), где значение 3 – это число каналов;
- передает предобработанные изображения во входной слой опорной модели, устанавливаемый сигнатурой слоя `numpy_inputs`.



Ниже приведен пример имплементации вызова опорной модели с подробным описанием:

- параметр `model` представляет собой скомпилированную модель `TF.Keras`, в которой метод `call()` является модельным методом для прямой подачи предсказания;
- метод `get_concrete_function()` строит обертку вокруг опорной модели для исполнения. Обертка предоставляет интерфейс для переключения исполнения в виде статического графа в функции обслуживания на динамический граф в опорной модели.

```
m_call = tf.function(model.call).get_concrete_function([tf.TensorSpec(shape=[None, 192, 192, 3], dtype=tf.float32, name="numpy_inputs")])
```

14.4.2 Пакетное предсказание

Пакетное предсказание отличается от развертывания модели для предсказания по требованию. В предсказании по требованию для развертывания модели вы создаете двоичный компонент обслуживания и платформу обслуживания; мы называем их *конечной точ-*

кой. Затем вы развертываете модель на этой конечной точке. Наконец, пользователи делают предсказательные запросы по требованию (в реальном времени) к конечной точке.

Напротив, пакетное предсказание начинается с создания пакетного задания для предсказания. Затем служба заданий выделяет ресурсы для пакетно-предсказательного запроса, и результаты возвращаются вызывающей стороне. Потом служба заданий высвобождает ресурсы для запроса.

Пакетное предсказание обычно используется, когда нет необходимости в немедленном ответе, поэтому ответ может быть отложен; число обрабатываемых предсказаний велико (исчисляется миллионами); и выделение вычислительных ресурсов необходимо только для обработки пакета.

В качестве примера рассмотрим финансовое учреждение, которое в конце каждого банковского дня имеет миллион транзакций, и у него есть модель для прогнозирования наперед на следующие 10 дней суммы депозитов и наличных денег в кассе. Поскольку прогнозирование всецело касается временного ряда, не имеет смысла и было бы неэффективно отправлять в службу предсказания по одной транзакции за раз в реальном времени. Вместо этого в конце банковского дня транзакционные данные извлекаются (например, из базы данных SQL) и отправляются в виде одного пакетного задания. Затем выделяются вычислительные ресурсы для двоичного компонента и платформы обслуживания, задание обрабатывается, и двоичный компонент и платформа обслуживания высвобождаются (выделение ресурсов отменяется).

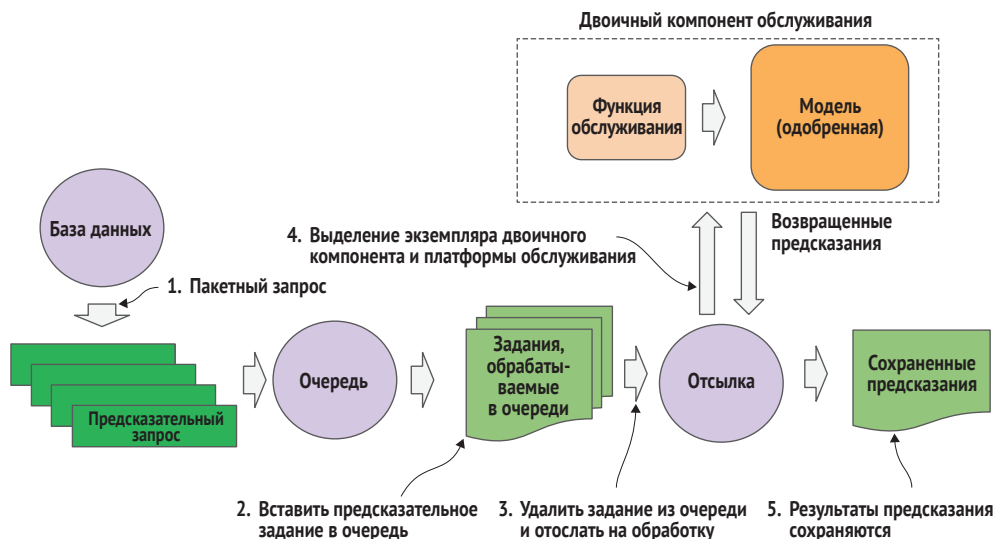


Рис. 14.20 Очередь и отправитель координируют выделение и высвобождение двоичного компонента и платформы обслуживания на основе каждого задания

На рис. 14.20 показана служба пакетного предсказания. Этот процесс состоит из пяти главенствующих шагов:

- 1 накопленные данные извлекаются и упаковываются в пакетный запрос, например из базы данных SQL;
- 2 пакетный запрос помещается в очередь, и менеджер очередей определяет требования к вычислительным ресурсам и приоритет;
- 3 пакетное задание при его готовности удаляется из очереди и направляется отправителю;
- 4 отправитель выделяет двоичный компонент и платформу обслуживания, затем отправляет пакетное задание;
- 5 по завершении пакетного задания результаты сохраняются, и отправитель высвобождает выделенные вычислительные ресурсы.

Далее мы рассмотрим вопрос о том, как модели развертываются в TFX для предсказания по требованию и для пакетного предсказания.

14.4.3 Конвейерные компоненты TFX для развертывания

В TFX конвейер развертывания состоит из компонентов *Pusher* и *Bulk Inference*, а также двоичного компонента и платформы обслуживания. Платформа обслуживания может быть облачной, локальной, периферийным устройством либо браузерной. Для облачных моделей рекомендуемой платформой обслуживания является *TensorFlow Serving*.

На рис. 14.21 показаны компоненты конвейера развертывания TFX. Выталкивающий компонент *Pusher* развертывает модели для предсказания по требованию либо для пакетного предсказания. Компонент массового предсказательного вывода *Bulk Inference* обрабатывает пакетные предсказания.

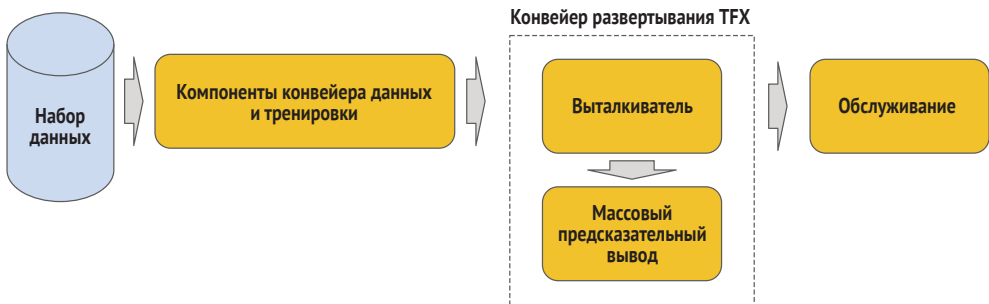


Рис. 14.21 Конвейер развертывания TFX может развертывать модель для обслуживания по требованию и/или массового предсказания

ВЫТАКИВАЕТСЯ

Ниже приведен пример имплементации, в котором показаны минимальные требования к инстанцированию компонента `Pusher` для развертывания модели в двоичном компоненте обслуживания:

- `model` – натренированная модель для развертывания в двоичном компоненте и платформе обслуживания (в данном случае экземпляр в настоящее время натренированной модели из компонента `Trainer`);
- `push_destination` – местоположение каталога в двоичном компоненте обслуживания для инсталлирования модели.

```
from tfx.components import Pusher
from tfx.proto import pusher_pb2

pusher = Pusher(model=trainer.outputs['model'],
                push_destination=pusher_pb2.PushDestination(
                    filesystem=pusher_pb2.PushDestination.FileSystem(
                        base_directory=serving_model_dir
                    )
                )
                )
```

Развертываемая натренированная модель

Местоположение в каталоге внутри двоичного компонента обслуживания, куда инсталлировать модель

Место назначения, куда двоичный компонент обслуживания должен развертывать модель

В производственной среде мы традиционно встраиваем модель в конвейер развертывания только в том случае, если это новая одобренная модель. Ниже приведен пример имплементации минимальных параметров, при которых модель развертывается только в том случае, если это новая одобренная модель:

- `model` – текущая натренированная модель из компонента `Trainer`;
- `model_blessing` – в настоящее время одобренная модель из компонента `Evaluator`.

В данном примере модель развертывается только в том случае, если модель и одобренная модель являются одним и тем же экземпляром модели:

```
pusher = Pusher(model=trainer.outputs['model'],
                model_blessing=evaluator.outputs['blessing'],
                push_destination=pusher_pb2.PushDestination(
                    filesystem=pusher_pb2.PushDestination.FileSystem(
                        base_directory=serving_model_dir
                    )
                )
                )
```

Натренированная в настоящее время модель

Экземпляр в настоящее время одобренной модели

Далее мы рассмотрим выполнение массового предсказания в TFX.

КОМПОНЕНТ МАССОВОГО ПРЕДСКАЗАТЕЛЬНОГО ВЫВОДА

Компонент `BulkInferer` выполняет службу пакетного предсказания, которая в документации TFX называется *массовым предсказательным выводом*. Следующий ниже исходный код является примером имплементации минимальных параметров, необходимых для выполнения пакетного предсказания натренированной в настоящее время моделью:

- `examples` – примеры, для которых нужно делать предсказания. В данном случае они поступают из экземпляра компонента `ExampleGen`;
- `model` – модель, используемая для пакетного предсказания (в данном случае натренированная в настоящее время модель);
- `inference_result` – место хранения результатов пакетного предсказания.

```
from tfx.components import BulkInferer

bulk_inferer = BulkInferer(examples=examples_gen.outputs['examples'],
                           model=trainer.outputs['model'],
                           inference_result=location)
```

Примеры, для которых необходимо
делать пакетное предсказание

Модель, используемая
для пакетного предсказания

Местоположение для хранения
результатов предсказания

Ниже приведен пример имплементации минимальных параметров, необходимых для выполнения пакетного предсказания с натренированной в настоящее время моделью, только если это модель одобрена, задаваемая параметром `model_blessing`. В данном примере пакетное предсказание выполняется только в том случае, если натренированная в настоящее время модель и экземпляр одобренной модели совпадают.

```
from tfx.components import BulkInferer

bulk_inferer = BulkInferer(examples=examples_gen.outputs['examples'],
                           model=trainer.outputs['model'],
                           model_blessing=evaluator.outputs['blessing'],
                           inference_result=location)
```

Экземпляр текущей
одобренной модели

14.4.4 A/B-тестирование

Сейчас мы завершили два теста нашей недавно натренированной модели, чтобы узнать о ее готовности стать следующей серийной версией, одобренной моделью. Мы провели прямое сравнение модельных метрик между двумя моделями, используя заранее определенные оценочные данные. И мы протестировали кандидатную модель в симулированной производственной среде, т. н. «песочнице».

Тем не менее без фактического развертывания кандидата мы по-прежнему остаемся неуверенными в том, что эта модель является бо-

лее оптимальной. Нам нужно оценить результативность кандидата в условиях *реального времени производственной среды*. Для этого мы передаем кандидату подмножество предсказаний в реальном времени и измеряем результат по каждому предсказанию между кандидатом и текущей производственной моделью. Затем анализируем мерные данные, или метрики, чтобы определить, действительно ли кандидатная модель является более оптимальной моделью.

Такая процедура называется *A/B-тестированием* в производственной среде машинного обучения. Рисунок 14.22 демонстрирует этот процесс. Как вы видите, обе модели развернуты в одной и той же предсказательной среде реального времени, при этом предсказательный трафик разделен между текущей одобренной моделью (A) и кандидатом на одобрение (B). Каждая модель видит случайную подборку предсказаний, которая основана на процентах.

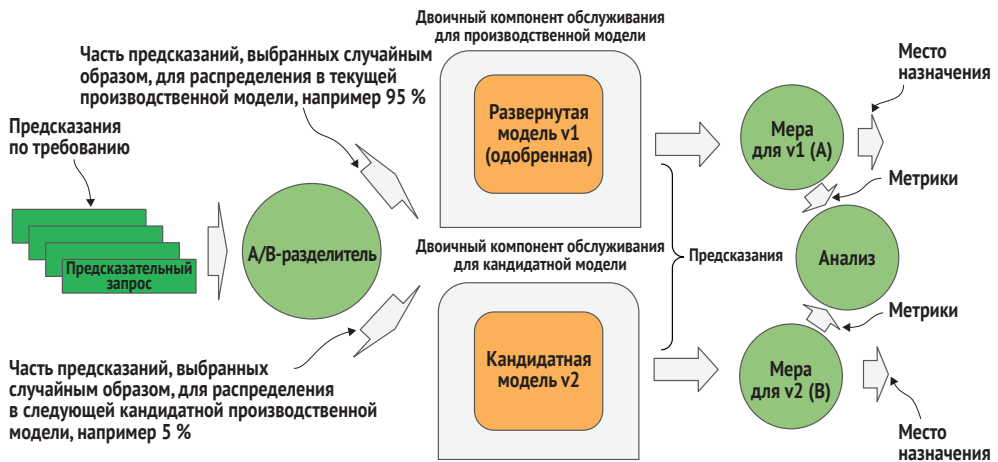


Рис. 14.22 A/B-тестирование текущей и кандидатной моделей в производственной среде реального времени, где кандидатная модель получает малый процент предсказаний в реальном времени

Мы не хотим иметь плохой результат в производстве, если кандидатная модель менее хороша, чем текущая модель. И поэтому мы обычно поддерживаем процент трафика как можно меньшим, но достаточным для измерения разницы между ними. Типичная разбивка составляет 5 % для кандидатной модели и 95 % для производственной модели.

Следующий вопрос: что измерять? Вы уже измеряли и сравнивали модельные метрики целевых критериев, поэтому повторять это не имеет большого смысла, в особенности если срезы оценивания включают как перекося в обслуживании, так и дрейф данных. Здесь следует измерять качество исхода для целевого критерия бизнеса.

Например, допустим, что ваша модель представляет собой модель классифицирования изображений, развернутую на производствен-

ной сборочной линии, которая отыскивает дефекты. Для каждой модели у вас есть две корзины: одна для исправных деталей и другая для дефектов. По истечении определенного периода времени ваш сотрудник по контролю качества инспектирует вручную распределение образцов из корзин как производственной модели, так и кандидатной модели, а затем их сравнивает. В частности, он хочет ответить на два вопроса:

- обнаруживает ли кандидатная модель равное или большее число дефектов, чем обнаруживает производственная модель? Это истинно положительные результаты (или истинные утверждения);
- обнаруживает ли кандидат равное или меньшее число дефектов? Это ложноположительные результаты (или ложные утверждения).

Как и в этом примере, вы должны определить целевой критерий бизнеса: увеличение истинно положительных результатов, уменьшение ложноположительных результатов или и то, и другое.

Давайте рассмотрим еще один пример. Допустим, мы работаем над языковой моделью на веб-сайте электронной коммерции, которая выполняет такие задачи, как создание подписей к изображениям, имеет чат-бота для вопросов о транзакциях и языковой перевод для ответов чат-бота пользователям. В этом случае измеряемой метрикой может быть суммарное число завершенных транзакций или средняя выручка от каждой транзакции. Другими словами, привлекает ли кандидатная модель более широкую аудиторию и/или приносит ли она более высокую выручку?

14.4.5 Балансировка нагрузки

После развертывания модели в производственной среде предсказаний по требованию объем предсказательных запросов с течением времени может существенно измениться. В идеале модель должна удовлетворять спросу на самом высоком пиковом уровне в пределах ограничений по задержке, а также минимизировать вычислительные затраты.

Мы могли бы удовлетворить первое требование, просто увеличив вычислительные ресурсы или число GPU, если модель монолитна, то есть она развертывается как единый экземпляр модели. Но это подорвало бы второе требование – минимизировать вычислительные затраты.

Как и в других современных облачных приложениях, когда трафик запросов существенно различается, мы используем автомасштабирование и балансировку нагрузки в целях распределенной обработки запросов. Давайте посмотрим, как автомасштабирование работает в условиях машинного обучения.

Термины «автомасштабирование» и «балансировка нагрузки» могут показаться взаимозаменяемыми. Но на самом деле это два

отдельных процесса, которые работают совместно. При *автомасштабировании* процесс заключается в выделении (добавлении) и высвобождении (удалении) вычислительных экземпляров в ответ на совокупную текущую загрузку предсказательными запросами. При *балансировке нагрузки* процесс определяет способ распределения текущей нагрузки предсказательными запросами по существующим выделенным вычислительным экземплярам и определяет момент, когда следует давать процессу автомасштабирования команду выделить или высвободить вычислительные экземпляры.

На рис. 14.23 показан сценарий балансировки нагрузки для производственной среды машинного обучения. По сути, вычислительный узел с балансировкой нагрузки получает предсказательные запросы, затем перенаправляет их в двоичный компонент обслуживания, который получает предсказательные ответы и направляет их обратно вызывающей стороне.

Давайте рассмотрим рис. 14.23 повнимательнее. Балансировщик нагрузки отслеживает нагрузки трафика, такие как частота предсказательных запросов в единицу времени, объем входящего и исходящего сетевых трафиков и время задержки при возврате ответа на предсказательный запрос.

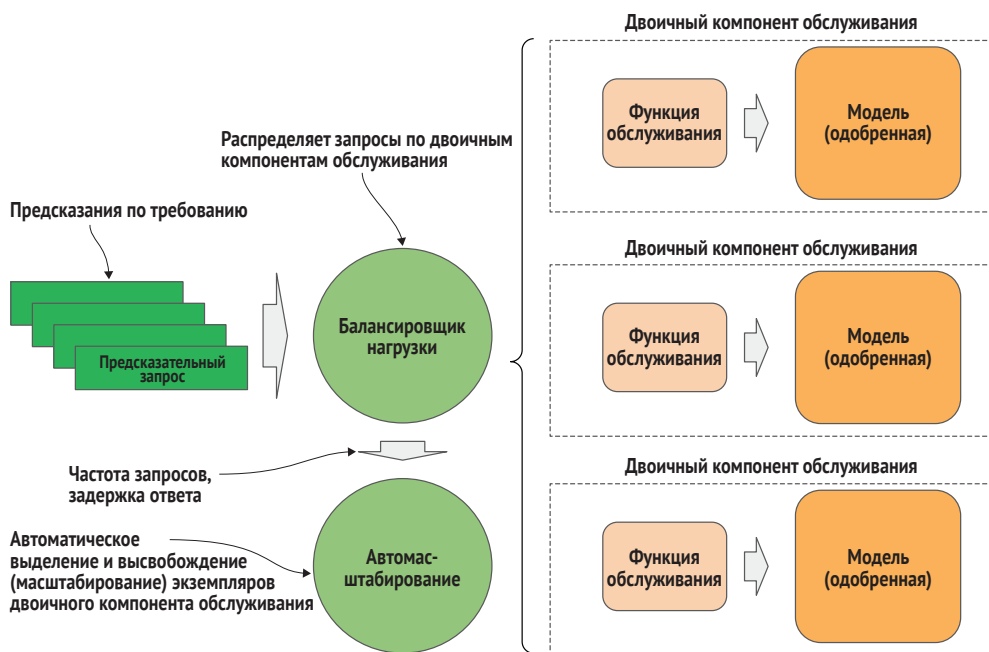


Рис. 14.23 Балансировщик нагрузки распределяет запросы по двоичным компонентам обслуживания, которые динамически выделяются и высвобождаются узлом автомасштабирования

Эти отслеживаемые данные подаются в реальном времени на узел автомасштабирования. Узел автомасштабирования конфигурирует-

ся персоналом MLOps в соответствии с критериями производительности. Если производительность ниже заранее определенного порога и продолжительности времени, то автопреобразователь масштаба динамически выделяет один или несколько новых дублированных экземпляров двоичного компонента обслуживания. Точно так же, если производительность превышает заданный порог и продолжительность времени, то автопреобразователь масштаба динамически высвобождает один или несколько существующих дублированных экземпляров двоичного компонента обслуживания.

Когда автопреобразователь масштаба добавляет двоичные компоненты обслуживания, он их регистрирует в балансировщике нагрузки. И схожим образом при удалении двоичных компонентов обслуживания он снимает регистрацию двоичных компонентов обслуживания у балансировщика нагрузки. Эти операции сообщают балансировщику нагрузки о том, какие двоичные компоненты обслуживания активны, чтобы балансировщик нагрузки мог распределять результаты предсказания.

В типичной ситуации балансировщик нагрузки конфигурируется с монитором работоспособности с целью отслеживания работоспособности каждого двоичного компонента обслуживания. Если двоичный компонент обслуживания определен как неработоспособный, то монитор работоспособности инструктирует узел автомасштабирования о высвобождении этого двоичного компонента обслуживания и выделении нового двоичного компонента обслуживания в качестве замены.

14.4.6 Непрерывное оценивание

Непрерывное оценивание (Continuous evaluation, аббр. CE) – это используемое в машинном обучении производственное расширение процесса разработки программно-информационного обеспечения непрерывной интеграции (CI) и непрерывного развертывания (CD). Указанное расширение обычно обозначается как CI/CD/CE. Непрерывное оценивание означает, что мы отслеживаем предсказательные запросы и ответы, которые модель получает после развертывания в производстве, и выполняем оценивание предсказательных ответов. Это аналогично тому, что делается при оценивании модели с использованием существующих тестового среза и срезов перекося в обслуживании и дрейфа данных. Это делается для обнаружения ухудшения результативности модели из-за изменений в предсказательных запросах во временной динамике, наблюдаемых в процессе производства.

Типичный процесс непрерывного оценивания заключается в следующем:

- предварительно сконфигурированный процент (например, 2 %) предсказательных запросов и ответов будет сохранен для оценивания вручную;

- сохраненные предсказательные запросы и ответы выбираются случайным образом;
- на некоторой периодической основе сохраненные предсказательные запросы и ответы регулярно анализируются и оцениваются в соответствии с модельными метриками целевого критерия;
- если оценивание определяет, что производительность модели ниже оценивания модельных метрик целевого критерия перед развертыванием, то специалисты по оцениванию вручную выявляют примеры недостаточной производительности, которые являются результатом перекоса в обслуживании, дрейфа данных и любой непредвиденной ситуации. Это аномалии;
- выявленные примеры помечаются вручную и добавляются в набор тренировочных данных, а часть откладывается в качестве соответствующих срезов оценивания;
- модель проходит либо инкрементную перетренировку, либо полную перетренировку.

На рис. 14.24 показан подход CI/CD/CE по интегрированию непрерывного оценивания из развернутой производственной модели в процесс разработки модели.

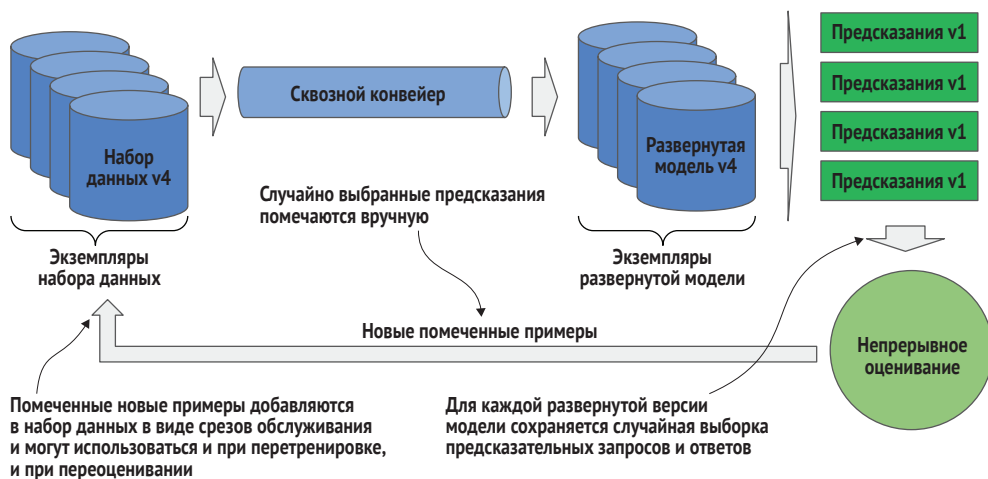


Рис. 14.24 Развернутая в производстве модель непрерывно оценивается на предмет выявления слаборезультативных примеров, которые затем добавляются в набор данных для перетренировки модели

14.5 Эволюция в конструировании производственных конвейеров

Давайте завершим эту книгу кратким обсуждением темы эволюции концепции и необходимости конвейера, когда машинное обучение перешло от исследований к полномасштабному производству. Воз-

можно, вам покажется особенно интересной часть, посвященная консолидации моделей, поскольку она является одним из следующих авангардных направлений в области глубокого обучения.

Каким образом эволюция подходов к машинному обучению повлияла на то, как мы на самом деле проводим машинное обучение? Разработка моделей глубокого обучения прошла путь от экспериментов в лаборатории до развертывания и использования в полномасштабной производственной среде.

14.5.1 Машинное обучение в качестве конвейера

Вы, вероятно, встречали это и раньше. Успешному инженеру машинного обучения необходимо раскладывать техническое решение в области машинного обучения на следующие ниже шаги:

- 1 определение типа модели для данной задачи;
- 2 конструирование модели;
- 3 подготовка данных для модели;
- 4 тренировка модели;
- 5 развертывание модели.

Инженер(ы) машинного обучения организовывал эти шаги в двухэтапный сквозной конвейер. Первый сквозной конвейер состоит из первых трех шагов, которые изображены на рис. 14.25 как моделирование, выработка/конструирование данных и тренировка. После того как инженер(ы) машинного обучения успешно справится с данным этапом, этот этап состыковывался с этапом развертывания с целью формирования второго сквозного конвейера. Модель традиционно развертывалась в контейнерной среде, и доступ к ней осуществлялся через интерфейс REST либо интерфейс микрослужбы.



Рис. 14.25 Преобладающая практика сквозного конвейера машинного обучения в 2017 году

Такая практика преобладала в 2017 году. Я называю ее *фазой открытия*. Что это за части, и как они вписываются друг в друга?

14.5.2 Машинное обучение как производственный процесс CI/CD

В 2018 году производственные предприятия формализовали процесс производства CI/CD, который я называю *фазой разведки*. Рисунок 14.26 является слайдом, который я использовал на презентации в Google для лиц, принимающих решения в бизнесе, в конце 2018 года, на котором показано, где мы тогда были. Этот процесс больше не был просто техническим, но включал интеграцию планирования и обеспечения качества. Выработка данных стала более определяемой как шаги извлечения, анализа, преобразования, управления и обслуживания. Конструирование моделей и их тренировка включали выработку/конструирование признаков, а развертывание расширилось, включив непрерывное усвоение.

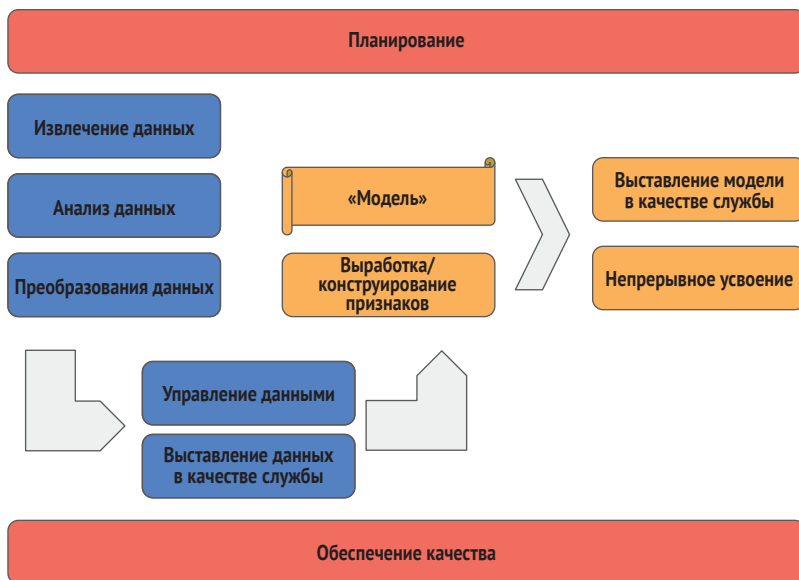


Рис. 14.26 К 2018 году Google и другие крупные производственные предприятия формализовали производственный процесс, включив в него шаги планирования и обеспечения качества, а также технический процесс

14.5.3 Консолидация моделей в производстве

Модели, которые сегодня находятся в производстве, не имеют единого выходного слоя. Вместо этого они имеют несколько выходных слоев, начиная с выделения существенных признаков (обычные слои), пространства представления, латентного пространства (векторы призна-

ков, кодировки) и пространства распределения вероятностей (мягкие и твердые метки). Модели теперь представляют собой целое приложение; внутреннего приложения серверного типа (бэкенда) нет.

Эти модели усваивают оптимальный путь к интерфейсу и обмену данными. Инженер машинного обучения на производственном предприятии 2021 года теперь руководит пространством поиска в рамках консолидации моделей, обобщенный пример которой показан на рис. 14.27.

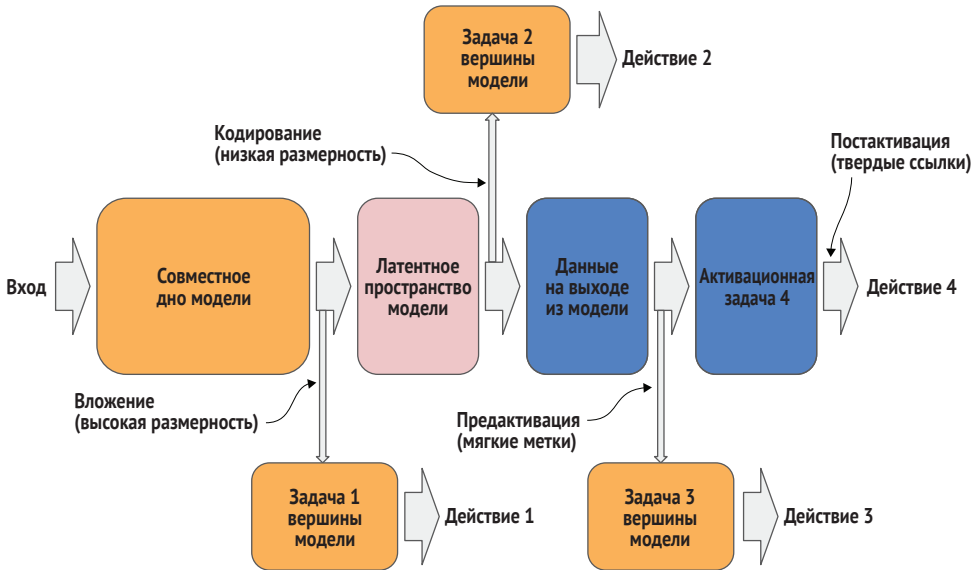


Рис. 14.27 Консолидация моделей – когда модели становятся целым приложением!

Давайте разберем этот обобщенный пример. С левой стороны находится место подачи данных на вход в консолидацию. Входные данные обрабатываются обычным набором сверточных слоев в так называемое *совместное дно модели*. Данные на выходе из совместного дна модели в этом описании имеют четыре усвоенных выходных представления: 1) высокоразмерное латентное пространство, 2) низкоразмерное скрытое пространство, 3) предактивационное условное распределение вероятностей и 4) постактивационное независимое распределение вероятностей.

Каждое из этих усвоенных выходных представлений реиспользуется специализированными нижестоящими усваиваемыми задачами, которые выполняют действие (например, изменение в переходе из состояния в состояние или преобразование). Каждая задача, представленная на рисунке как задачи 1, 2, 3 и 4, реиспользует выходное представление, которое является наиболее оптимальным (размер, скорость, точность) для цели задачи. Эти отдельные задачи могут затем продуцировать несколько усвоенных выходных представлений

или объединять усвоенные представления из нескольких задач (плотные вложения) для реиспользования в дальнейших нижестоящих задачах, как вы видели в примере спортивного вещания в главе 1.

Конвейеры обслуживания не только позволяют использовать решения такого типа, но и сами компоненты внутри конвейеров могут быть версионно контролируемыми и переконфигурируемыми. Это делает указанные компоненты реиспользуемыми, что является основополагающим принципом в современной инженерии программно-информационного обеспечения.

Резюме

- Базовыми компонентами конвейера тренировки являются подача данных в модели, оценивание моделей и планировщики тренировок.
- Относящиеся к целевому критерию метрики каждого экземпляра модели сохраняются в виде метаданных. Экземпляр модели одобряется, когда его критериальные метрики лучше, чем у текущей одобренной модели.
- Каждая одобренная модель отслеживается и проверяется в репозитории моделей.
- Когда модель подается для распределенной тренировки, размер пакета увеличивается, чтобы сгладить дисперсии между разными пакетами, которые подаются в параллельном режиме.
- В оркестровке управляющий интерфейс контролирует выполнение каждого компонента, запоминает выполнение предыдущих компонентов и ведет историю.
- Срезы оценивания состоят из примеров того же распределения, что и у тренировочных данных, и из примеров, не связанных с распределением, которые можно увидеть в производстве. К ним относятся перекося в обслуживании и дрейф данных.
- Базовыми компонентами конвейера развертывания являются развертывание, обслуживание, масштабирование и непрерывное оценивание.
- А/В-тестирование используется в реально существующих производственных средах, чтобы определять, является ли кандидатная модель лучше текущей производственной модели, например чтобы не нарушать производство, если произойдет что-то непредвиденное.
- Непрерывное оценивание используется в реально существующих производственных средах для выявления перекосов в обслуживании, дрейфа данных и аномалий, на основе которых в набор данных могут добавляться новые помеченные данные и проводится дальнейшая перетренировка модели.

Предметный указатель

Символы

`_build_model()`, функция, 484
`_get_hyperparameters()`, функция, 486
`_init_()`, метод, 453
`_input_fn()`, функция, 484
`_parse_function()`, функция, 440
`@tf.function`, декоратор, 506

А

A/B-тестирование, 512
Activation, класс, 62
activation, параметр, 87
activity_regularizer, параметр, 320
adagrad, метод, 65
Adam, оптимизатор, 65
adam, функция, 68
add(), метод, 51
alpha, параметр, 268
astype(), метод, 117
attrs, свойство, 431
AveragePooling2D, слой, 301

В

baseline_model, параметр, 502
batch() метод, 476
BatchNormalization, класс, 100, 176
binary_crossentropy, параметр, 62
binary_crossentropy, функция, 65
blessed_model, экземпляр, 503
block(), функция, 182
brightness_range, параметр, 150
bs (размер пакета)
 мини-пакетный градиентный спуск, 135

 пакетный градиентный спуск, 135
 стохастический градиентный спуск, 134
build(), метод, 454
build_model(), функция, 486
BulkInferer, компонент, 512
bypass, параметр, 292

С

CAD (компьютерный дизайн), 38
call(), метод, 453, 508
callbacks, параметр, 130
categorical_crossentropy, функция, 65, 68, 113, 115, 378
CD (непрерывное развертывание), 516
CE (непрерывное оценивание), 516
CenterCrop, слой, 448
CI (непрерывная интеграция), 516
CI/CD (непрерывная интеграция/непрерывная доставка), 128, 519
classifier(), функция, 248
CNN-сеть (сверточная нейронная сеть), 27, 75
 вне распределения, 412
 конструкция в форме ConvNet, 83
 обнаружение признаков, 79
 основания для использования, 77
 понижение размера (даунсэмплинг), 77
 разглаживание, 83
 сведение, 82
 сети ResNet, 92
 архитектура, 93
 пакетная нормализация, 99
 ResNet50, 100
 сети VGG, 88
compile(), метод, 60, 115, 168, 373

compression, параметр, 239
Conv2D, класс, 83, 85
Conv2D, слой, 87, 174, 289
conv_block(), процедура, 91
convert(), метод, 157, 306
create_model(), функция, 478
CSV (значения, разделенные запятыми), файл, 153
CT_small.dcm, тестовый набор данных, 432
custom_executor_spec, параметр, 483
cv2.imdecode(), метод, 159
cv2.imread(), метод, 158, 436
cv2.INTER_AREA, алгоритм, 159
cv2.INTER_AREA, интерполяция, 148
cv2.INTER_LINEAR, интерполяция, 148
cv2.resize(), интерполяция, 148
cv2.resize(), метод, 159

D

dataset, переменная, 441
decay, параметр, 357
decode_predictions(), метод, 374
Dense, класс, 53
Dense, слой, 281, 288, 313, 448
Dense(), слой, 113
DenseNet, 237
 блоки, 240
 группы, 237
 макроархитектура, 243
 переходные блоки, 243
 ученический компонент, 185
DICOM (цифровая визуализация и коммуникация в медицине), формат, 432
DNN-сеть (глубокая нейронная сеть), 27
 автокодировщики, 310
 архитектура, 310
 декодировщики, 313
 кодировщики, 312
 тренировка, 313
 вне распределения, 405
 входной слой
 в сопоставлении с входной формой, 52
 обзор, 47
 двоичный классификатор, 61
 метод последовательного API, 51
 метод функционального API, 52
 мультиклассовый классификатор, 63
 мультиметочный мультиклассовый классификатор, 66

 оптимизатор, 60
 плотный слой, 53
 простой классификатор изображений, 68
 переподгонка и отсев, 71
 простые классификаторы изображений
 разглаживание, 69
 сети прямого распространения, 51
 слои глубины, 50
 укороченный синтаксис, 59
dtype, 50

E

EarlyStopping, объект, 130
entryFlow(), функция, 248
epoch, параметр, 115
epochs, параметр, 134
eval_args, параметр, 483, 485
eval_config параметр, 502
eval_config, параметр, 502
evaluate(), метод, 117
Evaluator, компонент, 480, 501, 511
ExampleGen, компонент, 455, 501
examples, параметр, 483, 501, 512
ExampleValidator, компонент, 455
exitFlow(), функция, 248
export_path, параметр, 507
external_input(), метод, 457

F

FCNN (полносвязная нейронная сеть), 50
feature_description, словарь, 440
file.open(), метод, 437
filepath, параметр, 129
filters, параметр, 286, 412
fit(), метод, 113, 121, 130, 134, 135, 314, 355, 441, 442, 443, 475, 476, 484, 486
fit_generator(), метод, 417
Flatten, класс, 70, 85
Flatten, объект, 70
Flatten, слой, 87, 113
flip(), функция, 464
from_tensor_slices(), метод, 441

G

get_best_models(), метод, 356
get_concrete_функция(), метод, 508
get_model(), метод, 351

GlobalAveragePooling2D, слой, 97, 255, 273, 281, 289
GlobalAveragingPooling2D, слой, 288
glorot_uniform, распределение Ксавье, 341
Group, атрибут, 431
group(), функция, 182, 184

H

HDF5 (иерархический формат данных 5)
 группы, 429
 обзор, 427
he_normal, параметр, 342
hr, гиперпараметрическая контрольная переменная, 355
hr.Choice(), метод, 355

I

image, параметр, 464
ImageDataGenerator, класс, 139, 148, 416
Image.open(), метод, 154, 156
images, ключи, 429
ImportExampleGen, подкласс, 457
imutils, module, 143
Inception v1, 201
 вспомогательный классификатор, 208
 классификатор, 210
 модуль, 204
 нативный модуль Inception, 201
 стержневой компонент, 207
 ученический компонент, 207
Inception v2, 211
Inception v3, 214
 вспомогательный классификатор, 222
 группы и блоки, 215
 модернизация и имплементация стержня, 220
 нормальная свертка, 219
 пространственно разделяемая свертка, 220
include_top=False, параметр, 378
include_top, параметр, 378
inference_result, параметр, 512
InfraEvaluator, компонент, 480
InfraValidator, компонент, 503
Input, класс, 49, 54, 168
inputs, параметр, 454
input_shape, параметр, 53, 91, 376, 449, 453
instance_name, параметр, 502

J

JSON (объект нотации JavaScript), файл, 154

K

keras.applications, модуль, 372
KerasTuner, настройщик, 354
kernel_initializer, параметр, 341
kernel_regularizer, именованный параметр, 365
kernel_size, именованный параметр, 90
kernel_size, параметр, 84

L

L, параметр, 157
label, параметр, 464
labels, метки, 429
label_smoothing, именованный параметр, 367
Lambda(), метод, 227
Layer, инициализатор, 453
Layer, класс, 453
Layer, подклассирование, 455
layers, параметр, 313
learner(), функция, 181
LearningRateScheduler, обратный вызов, 358, 476
load_data(), функция, 112, 116
loadImages() функция, 157
load_weights(), метод, 161
LU (понимание естественного языка), 30

M

map(), метод, 440, 443, 464
MaxPool2D, класс, 85
MaxPooling2D, слой, 87, 285
max_value, аргумент, 270
metrics_specs, параметр, 502
middleFlow(), функция, 248
min_delta, параметр, 131
mnist(), модуль, 116
MobileNet редуцированная, 266
MobileNet v1, 264
 архитектура, 265
 классификатор, 273
 множитель разрешающей способности, 267
 множитель ширины, 266

- стержневой компонент, 268
- ученический компонент, 271
- MobileNet v2, 274
 - архитектура, 275
 - классификатор, 281
 - стержневой компонент, 276
 - ученический компонент, 277
- Model, класс, 52, 55, 68, 168
- Model(), объект, 55
- model, параметр, 502, 503, 508, 511, 512
- Model, подклассирование, 455
- model_blessing, параметр, 503
- ModelCheckpoint, класс, 129
- model.output, слой, 378
- models.input, модель ResNet, 378
- model_specs, параметр, 502
- model.summary(), 97
- module_file, скрипт, 483
- monitor, параметр, 130, 131

N

- name, параметр, 453
- n_blocks, параметр, 239, 297
- n_filters, параметр, 239, 301
- NLG (генерация естественного языка), 333
- NLP (обработка естественного языка), 29, 194
 - адаптируемость, 30
 - понимание естественного языка, 30, 194
 - трансформерная архитектура, 196
- NLTK (естественно-языковой инструментарий), 30
- NLU (понимание естественного языка), 194, 333
- nodes, параметр, 405
- n_partitions, параметр, 297, 300
- np.cos(), функция, 363
- np.mean(), метод, 118
- np.roll(), метод, 145
- np.std(), метод, 118
- np.uint8, формат данных, 438
- num_models, параметр, 356
- NumPy, библиотека, 116, 441
- num_replicas_in_sync, свойство, 480

O

- output, параметр, 484
- outputs, свойство, 457

P

- ParseFromString(), метод, 439
- path, параметр, 436
- patience, параметр, 131
- period, параметр, 130
- pip, команда, 354
- pip install, 48
- pip install scandir, команда, 155
- pool_size, именованный параметр, 90
- pool_size, параметр, 85
- predict(), метод, 306, 374
- preprocessed_input(), метод, 374
- preprocess_fn(), функция, 507
- preprocess_input(), метод, 374
- project_name, параметр, 356
- push_destination, параметр, 511
- Pusher, компонент, 511
- pw_group_conv(), функция, 299
- PyPI (каталог пакетов Python), 49

R

- RandomSearch, класс, 355
- ratio, параметр, 260
- reduction, параметр, 186, 297, 301
- relu, активационная функция, 113
- ReLU (rectified linear unit), 57
- repeat(), метод, 442
- Rescaling, класс, 453
- Rescaling, слой, 448
- Reshape, операция, 262
- Reshape, слой, 273
- residual_block(), 95
- resize(), метод, 158
- Resizing, слой, 448
- ResNet, 92
 - архитектура, 93
 - задачный компонент, 188
 - пакетная нормализация, 99
 - стержневой компонент, 171
 - ученический компонент, 182
- ResNet50, 100
- ResNeXt, 227
 - блок ResNeXt, 224
 - стержневой компонент, 176
 - широкие остаточные нейронные сети, 223
- resolver_class, параметр, 502
- ResolverNode, компонент, 502
- ResolverNode(), экземпляр, 503

REST (передача состояния представления данных), 41
 results_summary(), метод, 356
 rho, параметр, 268
 rmsprop, метод, 61, 65
 RNN (рекуррентная нейронная сеть), 196
 rot90(), метод, 143
 rotate(), метод, 144
 rotation_range, параметр, 149
 run_fn(), функция, 484, 486

S

save_best_only, параметр, 130
 save_weights(), метод, 160
 schema, параметр, 483
 SchemaGen, компонент, 455
 schema_gen, экземпляр, 459
 search(), метод, 355
 self.kernel, параметр, 454
 SE-Net (шаблон сдавливания-возбуждения-шкалирования), 258
 архитектура, 258
 группы и блоки, 259
 связь SE, 261
 Seq2Seq («последовательность в последовательность»), 333
 Sequential, класс, 51, 54
 Sequential, объект, 51
 serving_fn(), метод, 506
 serving_spec, параметр, 503
 SGD (стохастический градиентный спуск), 134
 shape, свойство, 48
 shortcut, переменная, 94, 242
 shuffle(), метод, 442
 ShuffleNet v1, 294
 архитектура, 295
 стержневой компонент, 295
 ученический компонент, 296
 блоки, 297
 блоки пошаговой перетасовки, 300
 группы, 296
 перетасовка каналов, 302
 точечная групповая свертка, 300
 slicing_specs, параметр, 502
 softmax, слой, 113
 sparse_categorical_crossentropy, функция, 115
 split_names, свойство, 457
 squeeze_excite_link(), функция, 259
 SqueezeNet, 282

архитектура, 283
 задачный компонент, 192
 классификатор, 288
 обходные соединения, 290
 простой обходной путь, 291
 сложный обходной путь, 293
 стержневой компонент, 284
 ученический компонент, 285
 SRCNN (сверхразрешающая сверточная нейросетевая модель), 322
 statistics, ключ/значение, 458
 StatisticsGen, компонент, 455
 statistics_gen, экземпляр, 458, 459
 stem(), компонент, 325
 steps_per_epoch, параметр, 134, 475
 strides, параметр, 84
 summary(), метод, 58, 70, 203, 205, 214, 222, 332, 406
 super(), функция, 453

T

tensorflow_hub, модуль Python, 381
 tf.data, конвейер, 461
 tf.data, модуль, 443
 tf.data.Dataset, класс, 440
 tf.data.TFRecordDataset, класс, 440
 tf.distribute.Strategy, модуль, 478
 tf.Example, объект, признаки, 435
 tf.function, декоратор, 454
 tf.image, модуль, 139
 tf.image.convert_image_dtype(), операция статического графа, 507
 tf.image.random_crop(), метод, 464
 tf.image.resize(), операция статического графа, 508
 tf.io.decode_jpeg(), операция статического графа, 507
 tf.io.parse_single_example(), метод, 444
 tf.io.TFRecordWriter, функция, 439
 TF.Keras, предварительно построенные модели, 371
 базовая модель, 372
 новый классификатор, 375
 преднатренированные на ImageNet модели для предсказания, 374
 TF.Keras, модуль, 49
 TF.Keras ImageDataGenerator класс
 масштабирование, 150
 повороты, 149
 сдвиги, 150
 яркость, 150

- TF.Keras ImageDataGenerator, класс, 148
 перевороты, 148
TF.Keras.Layer, класс, 453
TF.Keras.layers.experimental.preprocessing,
модуль, 465
TFRecord, формат, 434
 загрузка/чтение записей, 439
 объект tf.Example
 несжатые изображения, 437
 сжатые изображения, 436
 подача данных, 443
 несжатые изображения, 445
 сжатые изображения, 444
 tf.Example, объект, признаки, 435
TFRecordDataset(), метод, 443
TFRecord format
 выгрузка записей, 439
 объект tf.Example
 полная готовность к машинному
 обучению, 438
tf.saved_model.save(), функция, 507
tf.string, строковый литерал, 507
tf.train.ByteString, тип данных, 435
tf.train.Example, запись, 437
tf.train.Example, объект, 436
tf.train.FloatList, тип данных, 435
tf.train.Int64List, тип данных, 435
tft.TFTransformOutput(), функция, 484
TFX (TensorFlow Extended), 420, 455, 468
 конвейерные компоненты для
 развертывания, 510
 компонент BulkInferer, 512
 компонент Pusher, 511
 оценивание модели, 501
 компонент Evaluator, 501
 InfraValidator, компонент, 503
 подача данных в модель, 480
 компонент Trainer, 482
 компонент Tuner, 485
 оркестровка, 481
 предобработка данных, 455
 компонент ExampleGen, 457
 компонент ExampleValidator, 459
 компонент SchemaGen, 458
 компонент StatisticsGen, 457
 предобработка данных с помощью
 компонента Transform, 460
to_categorical(), функция, 114
trainable, свойство, 386
train_args, параметр, 483, 485
Trainer, компонент, 480, 482, 501, 511
train_on_batch(), метод, 429
Transform, компонент, 483
transformed_examples, параметр, 483
transform_graph, параметр, 483
Tuner, компонент, 480, 485
tuner_fn(), функция, 485
-
- ## U
- UpSampling2D, слой, 332
uri, свойство, 457
-
- ## V
- val_acc, параметр, 130
validation_split, параметр, 121
val_loss, параметр, 130
VGG (группа визуальной геометрии)
 архитектура, стержневой
 компонент, 169
-
- ## W
- where(), метод, 48
width_shift_range, параметр, 150, 416
WRN (широкая остаточная сеть), 227
 широкие остаточные блоки, 229
 WRN-50-2, 228
-
- ## X
- x, переменная, 63
Xception (экстремальное начало), 245
 архитектура, 245
 входной поток, 249
 выходной поток, 253
 свертка глубь, 256
 свертка, разделяемая по глубине, 256
 срединный поток, 252
 стержневой компонент, 178
 точечная свертка, 256
x_train, массив, 324
x_train, параметрическое значение, 441
x_train_lr, зеркальный список, 327
-
- ## Z
- ZeroPadding
 слои, 177
ZeroPadding2D
 слои, 174
zoom_range, параметр, 150

А

Аббревиатура, 95
 Автокодировщик, 334
 автокодировщики для устранения шума, 321
 автокодировщики
 сверхразрешения, 323
 сверхразрешение на основе постотбора с повышенной частотой, 326
 сверхразрешение на основе предотбора с повышенной частотой, 323
 глубокие нейросетевые автокодировщики, 310
 архитектура, 310
 декодировщики, 313
 кодировщики, 312
 тренировка, 313
 предлоговые задачи, 330
 разряженные автокодировщики, 320
 сверточные автокодировщики, 315
 архитектура, 316
 декодировщики, 318
 кодировщики, 317
 Seq2Seq, 333
 Автокодировщик для устранения шума, 321
 Автокодировщик разряженный, 320
 Автокодировщик сверточный, 315
 архитектура, 316
 декодировщики, 318
 кодировщики, 317
 Автокодировщик сверхразрешения (SR), 323
 сверхразрешение на основе постотбора с повышенной частотой, 326
 сверхразрешение на основе предотбора с повышенной частотой, 323
 Автомасштабирование, 514
 Автоматизация интеллектуальная (ИА), 35
 Адаптируемость, 27
 компьютерное зрение, 29
 обработка естественного языка, 30
 понимание естественного языка, 30
 структурированные данные, 30
 Алгоритм рампового ската, 359
 Артефакт, 492
 Архитектура нейросетевая, 167

Архитектура с осведомленностью о задаче, 481
 Архитектура трансформерная, 196
 Архитектура VGG (группа по визуальной геометрии), обзор, 88

Б

Балансировка нагрузки, 514
 Без дополнения, 80
 Блок
 DenseNet, 240
 Inception v3, 215
 ResNeXt, 224
 SE-Net, 259
 ShuffleNet v1, 297
 остаточный бутылочный, 98
 остаточный инвертированный, 277
 переходной, 185, 243
 пошаговой перетасовки, 300
 широкие остаточные сети, 229

В

Валидация, 119
 Валидация перекрестная, 119
 Вектор, 47
 Вектор признаков, 281, 383
 Вершина модели, 108
 Вес предметно-специфичный, 390
 Взаимосвязь линейная, 397
 Вложение, 190, 281
 Вложение низкоразмерное, 240
 Вне распределения, 402
 заключительный тест, 418
 курируемый набор данных MNIST, 402
 настройка среды, 403
 обогащение изображений, 415
 серьезное испытание, 404
 тренировка в качестве глубокой нейросети, 405
 тренировка в качестве сверточной нейросети, 412
 Восстановление модели для развертывания, 160
 Восстановление размерности, 241
 Выборка случайная, 398
 Вывод предсказательный, 83, 108, 112
 Выстраивание предстержней в цепочку, 451

Г

Генерирование естественного языка.
См. *NLG*
Гиперпараметр, 131, 282
 размер пакета, 134
 мини-пакетный градиентный
 спуск, 135
 пакетный градиентный спуск, 135
 стохастический градиентный
 спуск, 134
 скорость усвоения, 135
 адаптивная скорость усвоения, 138
 затухание, 137
 малая и большая, 135
 моментум, 138
 шаги, 132
 эпохи, 132
Гипотеза лотерейная, 342
Горлышко бутылочное, 101, 188, 204
Градиент исчезающий, 99, 124, 209
Группа
 DenseNet, 237
 Inception v3, 215
 SE-Net, 259
 ShuffleNet v1, 296
Группа по операциям машинного
обучения, 496
Группа сверточная, 89

Д

Данные многомерные, 427
Данные непрерывные, 32
Данные отложенные, 71
Данные структурированные, 30, 230
Даунсэмплинг. См. *Понижение (изменение)
размера*
Дизайн компьютерный (CAD), 38
Дизайн машинный, 38
Дно модели, 108
Дно модели совместное, 520
Дополнение, 80, 87, 174, 207
Дрейф данных, 330, 397, 402, 498

З

Задача, 44, 316
Задача несовпадающая, 387
Задача похожая, 385
Задача предлоговая, 330
Закаливание косинусное, 361

Запись для кодирования
изображения, 436
Запись для соответствующей метки, 436
Запись для формы изображения, 436
Запоминание, 231
Затухание, 137
Затухание фиксированное, 137
Зрение компьютерное, 29

И

ИА (интеллектуальная
автоматизация), 35
Изменение масштаба, 499
Изменение размера
 набор данных сырой (дисковый), 157
 сверточные нейронные сети, 77
Изменение размера (даунсэмплинг), 77
ИИ (искусственный интеллект), 31
 классический, 31
 семантический, 31
 статистический, 32
 узкий, 31
Инвариантность, 138, 461
 TF.Keras ImageDataGenerator, класс, 148
 масштабирование, 150
 перевороты, 148
 повороты, 149
 сдвиги, 150
 яркость, 150
 инвариантность трансляционная
 операции транспонирования, 142
 повороты, 143
 сдвиги, 145
 масштабная инвариантность, 147
 произвольная обрезка по центру, 461
 произвольные повороты, 463
 произвольные сдвиги, 463
 произвольный переворот, 462
 трансляционная инвариантность, 140
 перевороты, 140
Инвариантность масштабная, 147
Инвариантность трансляционная, 79, 140
 операции транспонирования, 142
 перевороты, 140
 повороты, 143
 сдвиги, 145
Инициализация, 340
Инициализация весов, 340
 лотерейная гипотеза, 342
 распределение весов, 341
 численная стабилизация, 344

Инициализация предметно-переносимыми весами, 392
 Инструментарий естественно-языковой (NLTK), 30
 Инструмент командной строки `pip`, 48
 Интерполяция, 324
 Интерполяция бикубическая, 324
 Интерполяция кубическая, 324
 Искусственный интеллект (ИИ), 31
 Исследование абляционное, 171
 Истина эмпирическая, 107
 История, 492
 Итераторы изображений на диске, компонент, 490

К

Канал, 258, 279
 Канал выходной, 277
 Кардинальность, 223
 Квантизация, 270
 Классификатор
 Inception v1
 вспомогательный классификатор, 208
 классификатор, 210
 Inception v3, 222
 MobileNet v1, 273
 MobileNet v2, 281
 SqueezeNet, 288
 глубокие нейронные сети
 двоичный классификатор, 61
 мультиклассовый классификатор, 63
 мультиметочный мультиклассовый классификатор, 66
 простой классификатор изображений, 68
 предварительно построенные модели
 TF Hub, 383
 предварительно построенные модели
 TF.Keras, 375
 вспомогательный
 Inception v1, 208
 Inception v3, 222
 двоичный, 61
 изображений простой, 68
 перепогонка и отсев, 71
 разглаживание, 69
 логистический, 61
 мультиклассовый, 63
 мультиклассовый мультиметочный, 66
 новый, 385
 Кодирование с одним активным состоянием, 114
 Кодировка, 189
 Кодировка высокоразмерная, 254
 Кодировщик стержневой, 196
 Компонент
 задачный, 188
 ResNet, 188
 SqueezeNet, 192
 многослойный выход, 189
 классификационный, 188
 стержневой, 170
 Inception v1, 207
 Inception v3, 220
 ResNet, 171
 ResNeXt, 176
 VGG, 169
 Xception, 178
 ученический, 180
 Inception v1, 207
 архитектура DenseNet, 185
 архитектура ResNet, 182
 Конвейер, 421
 Конвейер данных, 466
 обогащение данных, 461
 инвариантность, 461
 предстержень, 465
 с помощью `tf.data`, 464
 подача данных, 440
 NumPy, 441
 TFRecord, 443
 предобработка данных, 446
 с помощью предстержня, 446
 с помощью TF Extended, 455
 формат и хранение данных, 422
 формат изображений сжатый и сырой, 423
 формат DICOM, 432
 формат HDF5, 427
 Формат и хранение данных
 формат TFRecord, 434
 Конвейер обслуживания, 42
 Конвейер тренировки и развертывания, 521
 модельное оценивание
 кандидатная и одобренная модель, 496
 обслуживание запросов, 504
 конвейерные компоненты TFX для развертывания, 510
 обслуживание по требованию (в реальном времени), 505

- А/В-тестирование, 512
- обслуживание запросов
 - балансировка нагрузки, 514
 - непрерывное оценивание, 516
 - пакетное предсказание, 508
- оценивание модели
 - оценивание в TFX, 501
- оценивание моделей, 496
- планировщики тренировок, 488
 - версионирование конвейера, 490
 - история, 494
 - метаданные, 492
- подача данных в модель, 469
 - для последовательной тренировки, 470
 - для распределенной тренировки, 471
 - распределенная подача данных с помощью tf.strategy, 478
 - с помощью параметрического сервера, 473
 - с помощью tf.data.dataset, 474
 - с помощью TFX, 480
- эволюция, 517
 - консолидация моделей в производстве, 519
 - машинное обучение в качестве конвейера, 518
 - машинное обучение в качестве производственного процесса, 519
- Консолидация моделей, 40, 519
- Конструкция в форме ConvNet для CNN-сети, 83
- Кортеж, 54

М

- Макроархитектура, 282
- Масштабирование
 - TF.Keras ImageDataGenerator, класс, 150
 - масштабная инвариантность, 147
- Матрица, 47
- Метаданные, 492
- Метапараметр, 282, 297
- Метка, 60
- Метод оптимальный, 204
- Метод последовательного API, 51
- Метод функционального API, 52
- Микроархитектура, 282, 290
- Множитель разрешающей способности
 - параметр, 265
- Множитель ширины, параметр, 265
- Модель
 - кандидатная, 496
 - многозадачная, 68
 - мультимодальная, 433
 - оберточная, 465
 - оберточная Sequential, 179
 - одобренная, 496
 - предварительно построенная, 369
 - преднатренированная, 369
 - TF Hub (TensorFlow Hub)
 - предварительно построенная, 380
 - новый классификатор, 383
 - применение, 381
- Модуль, 283
 - Inception (начальный), 201
 - огневой, 264, 282
- Моментум, 138
- Мощность представительная, 98

Н

- Набор данных курируемый, 110, 150
- Набор данных сырой (дисковый), 150
 - изменение размера, 157
 - каталожная структура, 150
 - файлы CSV, 153
 - файлы JSON, 154
 - чтение изображений, 154
- Набор данных MNIST курируемый, 402
- Набор инвертированный, 404
- Набор отложенный, 405, 407
- Набор сдвинутый, 404
- Настройка, 338
- Настройка гиперпараметрическая, 368
 - инициализация весов, 340
 - лотерейная гипотеза, 342
 - распределения весов, 341
 - численная стабилизация, 344
- основы поиска, 347
 - решеточный поиск, 350
 - ручной метод, 349
 - случайный поиск, 351
 - KerasTuner, 354
- планировщик скорости усвоения, 357
 - алгоритм рампового ската, 359
 - косинусное закаливание, 361
 - параметр затухания в Keras, 357
 - планировщик скорости усвоения в Keras, 358
 - постоянный шаг, 360
- регуляризация, 364
 - регуляризация весов, 364

сглаживание меток, 365
 Настройка начальной скорости усвоения
 грубая, 349
 Настройка тонкая начальной скорости
 усвоения, 350
 Настройка уровня пакета, 349
 Нелинейность, 55, 64
 Непрерывная интеграция/непрерывная
 доставка (CI/CD), 128, 519
 Непрерывная интеграция (CI), 516
 Непрерывное оценивание (CE), 516
 Непрерывное развертывание (CD), 516
 Нормализация, 47, 116
 обзор, 116
 стандартизация, 118
 Нормализация пакетная, 99
 Нормализация пакетная
 преактивационная, 104

O

Оберточная модель, 448
 Обнаружение признаков, 79
 Обобщение, 231
 Обогащение данных, 460
 инвариантность, 461
 произвольная обрезка по центру, 461
 произвольные повороты, 463
 произвольные сдвиги, 463
 произвольный переворот, 462
 предстержень, 465
 с помощью tf.data, 464
 Образец, 109
 Обрезка, 461
 Обслуживание запросов, 504
 балансировка нагрузки, 514
 конвейерные компоненты TFX для
 развертывания, 510
 компонент BulkInferer, 512
 компонент Pusher, 511
 непрерывное оценивание, 516
 обслуживание по требованию
 (в реальном времени), 505
 пакетное предсказание, 508
 А/В-тестирование, 512
 Обслуживание по требованию
 (в реальном времени), 505
 Обучение машинное, 44
 адаптируемость, 27
 компьютерное зрение, 29
 обработка естественного языка, 30
 понимание естественного языка, 30

структурированные данные, 30
 в качестве конвейера, 518
 в качестве производственного процесса
 CI/CD, 519
 выгоды от шаблонов
 конструирования, 42
 эволюция, 31
 интеллектуальная автоматизация, 35
 классический ИИ против узкого ИИ, 31
 консолидация моделей, 40
 машинный дизайн, 38
 сращивание моделей, 39
 Ограничение по разряженности, 320
 Операция масштабирования, 224
 Оптимизатор, повышение точности, 60
 Оркестровка, 481
 Остановка ранняя, 130
 Отбор с пониженной частотой
 изменение размера, 77
 Отсев, 71
 Отсев, слой, 273
 Оценивание, 112
 Оценивание модели, 496
 кандидатная и освященная модель
 дрейф данных, 498
 изменение масштаба, 499
 перекос в обслуживании
 производственных запросов, 497
 оценивание в TFX, 501
 компонент Evaluator, 501
 InfraValidator, компонент, 503
 Оценивание модельное
 кандидатная и одобренная
 модель, 496

P

Пакет, 108
 Параметр, 53, 77, 399
 Параметр затухания в Keras, 357
 Параметр усваиваемый, 131
 Переверот матричный, 140
 Переворот
 произвольный, 462
 трансляционная инвариантность, 140
 TF.Keras ImageDataGenerator, класс, 148
 Перекос в обслуживании
 производственных запросов, 397, 402, 497
 Переменная зависимая, 107
 Переменная независимая, 107
 Перенос обучения, 394
 между предметными областями, 385

- инициализация предметно-переносимыми весами, 392
- несовпадающие задачи, 387
- отрицательный перенос, 394
- похожие задачи, 385
- предметно-специфичные веса, 390
- предварительно построенные модели
- TF Hub, 380
 - новый классификатор, 383
 - применение, 381
- предварительно построенные модели
- TF.Keras, 371
 - базовая модель, 372
 - новый классификатор, 375
 - преднатренированные на ImageNet модели для предсказания, 374
- Перенос отрицательный, 394
- Переподгонка, 71, 119, 200
 - валидация, 119
 - слежение за потерей, 123
 - слои, 123
- Перетасовка каналов, 302
- Персептрон многослойный (MLP), 109
- Песочница. См. *Среда производственная симулированная*
- Планировщик скорости усвоения, 357
 - алгоритм рампового ската, 359
 - косинусное закаливание, 361
 - параметр затухания в Keras, 357
 - планировщик скорости усвоения в Keras, 358
 - постоянный шаг, 360
- Планировщик скорости усвоения в Keras, 358
- Планировщик тренировки, 488
 - версионирование конвейера, 490
 - история, 494
 - метаданные, 492
- План скорости усвоения, 350
- Поворот
 - инвариантность трансляционная, 143
 - произвольный, 463
- Повороты, TF.Keras ImageDataGenerator, класс, 149
- Подача данных, 108, 440
 - подача данных в модель, 469
 - TFRecord, 443
 - несжатые изображения, 445
 - сжатые изображения, 444
- Подача данных в модель, 469
 - для последовательной тренировки, 470
 - для распределенной тренировки, 471
- распределенная подача данных
 - с помощью tf.strategy, 478
 - с помощью параметрического сервера, 473
 - с помощью tf.data.dataset, 474
 - динамическое обновление размера пакета, 475
 - с помощью TFX, 480
 - компонент Tuner, 485
 - оркестровка, 481
 - with TFX, компонент Trainer, 482
- Подача данных распределенная
 - с помощью tf.strategy, 478
- Подвыборка (прореживание), 82
- Подклассирование слоев TF.Keras, 453
- Подход к сверхразрешению на основе предотбора с повышенной частотой, 323
- Поиск гиперпараметрический, 347
 - решеточный поиск, 350
 - ручной метод, 349
 - грубая настройка начальной скорости усвоения, 349
 - настройка уровня пакета, 349
 - план скорости усвоения, 350
 - тонкая настройка начальной скорости усвоения, 350
 - случайный поиск, 351
 - KerasTuner, 354
- Поиск решеточный, 350
- Поиск случайный, 351
- Понижение (изменение) размера, 77
- Понижение размера карты признаков, 82
- Понимание естественного языка (NLU), 30, 194, 333
- Потеря, 60, 107
- Предобработка данных, 446
 - выстраивание предстержней в цепочку, 451
 - подклассирование слоев TF.Keras, 453
 - предобрабатывающий слой TF.Keras, 448
 - с помощью предстержня, 446
 - с помощью TFX, 455
 - компонент ExampleGen, 457
 - компонент ExampleValidator, 459
 - компонент SchemaGen, 458
 - компонент StatisticsGen, 457
 - компонент Transform, 460
- Предсказание пакетное, 508
- Представление промежуточное, 196, 334
- Предстержень
 - обогащение данных, 465

предобработка данных, 446
 выстраивание предстержней
 в цепочку, 451
 подклассирование слоев TF.Keras, 453
 предобрабатывающие слои
 TF.Keras, 448
 шаблон процедурного
 конструирования, 179
 Преобразование набора данных, 441
 Преобразования в памяти,
 компоненты, 490
 Проекция линейная, 100, 204
 Пространство латентное, 167, 314
 Путь обходной простой, 291
 Путь обходной сложный, 293

P

Разбивка набора данных, 111
 кодирование с одним активным
 состоянием, 114
 тренировочный и тестовый наборы, 111
 Разбивка-преобразование-слияние, 224
 Развертка, 316
 Размерность высокая, 427
 Размер пакета, 108
 Размер пакета (bs), 50, 134, 351
 Распределение весов, 341
 Распределение выборочное, 32, 399
 Распределение данных, 419
 вне распределения, 402
 заключительный тест, 418
 курируемый набор данных MNIST, 402
 настройка среды, 403
 обогащение изображений, 415
 серьезное испытание, 404
 тренировка в качестве глубокой
 нейросети, 405
 тренировка в качестве сверточной
 нейросети, 412
 типы распределений, 397
 выборочное распределение, 399
 Распределение Ксавье, 341
 Распределение подпопуляционное, 401
 Распределение популяционное, 32, 132,
 398
 Распределение предактивационных
 вероятностей, 190
 Распределение равномерное, 341
 Распределение Хе-нормальное, 341
 Распределения данных, типы
 подпопуляционное распределение, 401

 популяционное распределение, 398
 Распространение обратное, 60, 108
 пакетное обратное
 распространение, 110
 предпосылки, 108
 Регрессор, 60
 Регуляризация, 72, 364
 весов, 364
 весовая, 210
 сглаживание меток, 365
 слоевая, 340
 ядерная, 340
 Редукция размерности, 204
 Редукция решетки, 217
 Режим предсказательного вывода, 71
 Режим предсказания, 71
 Реиспользование (карт) признаков, 237
 Реиспользование признаков, 236
 Реиспользование процедурное, 43
 Рекуррентная нейронная сеть (RNN), 196

C

Сведение, 82, 377
 Сведение признаков, 82, 243
 Свертка
 вглубь, 256
 в форме бутылочного горлышка, 98
 групповая, 223
 групповая точечная, 300
 нормальная, 219
 пространственно разделяемая, 220
 разделяемая по глубине, 256
 точечная, 256
 Сверхразрешение на основе постотбора
 с повышенной частотой, 326
 Сверхразрешение на основе предотбора
 с повышенной частотой, 323
 Связь быстрого доступа, 95
 Связь отождествляющая, 76, 92
 Сглаживание меток, 365
 Сдвиг
 TF.Keras ImageDataGenerator, класс, 150
 инвариантность трансляционная, 145
 произвольный, 463
 Сдвиг ковариантный, 93
 Сервер параметрический, подача данных
 в модель, 473
 Сеть глубокая нейронная. См. *DNN-сеть*
 Сеть нейронная полносвязная (FCNN), 50
 Сеть нейронная сверточная
 мобильная, 308

- MobileNet v1, 264
 - архитектура, 265
 - классификатор, 273
 - множитель разрешающей способности, 267
 - множитель ширины, 266
 - стержневой компонент, 268
 - ученический компонент, 271
- MobileNet v2, 274
 - архитектура, 275
 - классификатор, 281
 - стержневой компонент, 276
 - ученический компонент, 277
- ShuffleNet v1, 294
 - архитектура, 295
 - стержневой компонент, 295
 - ученический компонент, 296
- SqueezeNet, 282
 - архитектура, 283
 - классификатор, 288
 - обходные соединения, 290
 - стержневой компонент, 284
 - ученический компонент, 285
- развертывание, 304
 - квантизация, 304
 - конверсия и предсказание в TF Lite, 306
- Сеть нейронная сверточная
 - плотносвязанная, 237
 - блоки, 240
 - группы, 237
 - макроархитектура DenseNet, 243
 - плотные переходные блоки, 243
- Сеть нейронная сверточная широкая, 233
- Inception v1, 201
 - вспомогательный классификатор, 208
 - классификатор, 210
 - модуль Inception v1, 204
 - нативный модуль Inception, 201
 - стержневой компонент, 207
 - ученический компонент, 207
- Inception v2, 211
- Inception v3, 214
 - вспомогательный классификатор, 222
 - группы и блоки, 215
 - модернизация и имплементация стержня, 220
 - нормальная свертка, 219
 - пространственно разделяемая свертка, 220
- структурированные данные, 230
- широкие остаточные нейронные сети, 223
 - ResNeXt, 227
 - блок ResNeXt, 224
 - широкие остаточные сети, 227
 - WRN-50-2, 228
 - широкие остаточные блоки, 229
- Сеть нейронная с множественным выходом, 68
- Сеть прямого распространения, 51
- Синтаксис укороченный, 59
- Скорость усвоения, 135
 - адаптивная скорость усвоения, 138
 - затухание, 137
 - малая и большая, 135
 - моментум, 138
 - циклическая, 361
- Скорость усвоения (lr), 351
- Слежение за потерей, 123
- Слой
 - TF.Keras преобразующий, 448
 - более узкий, 238
 - бутылочный, 187
 - валидация и переподгонка, 123
 - входной
 - в сопоставлении с входной формой, 52
 - обзор, 47
 - выходной параллельный, 67
 - глубокий, 50
 - классификаторный, 188
 - отсева, 72, 210
 - плотный, 53, 61, 88, 96, 188, 210, 256
 - подклассирование слоев TF.Keras, 453
 - преобразующий слой TF.Keras, 448
 - сверточный, 76, 79
 - сдавливания, 286
 - скрытый, 50
 - слои глубины, 50
- Смещение, 52, 58
- Соединение обходное, 290
 - простой обходной путь, 291
 - сложный обходной путь, 293
- Софтмакс, функция, 64
- Сохранение модельной архитектуры, 160
- Спуск градиентный, 60, 110
 - мини-пакетный, 135
 - пакетный, 135
 - стохастический (SGD), 134
- Сращивание моделей, 39
- Среда производственная симулированная, 469
- Срез оценивания, 469, 499

Стабилизация численная, 344
Стадия, 295
Стандартизация, 47, 118
Стержень, 44, 316
Структура каталожная, 151
Схождение, 60, 125

Т

Тензор, 47
Точка зрения, 39
Транспонирование, 142
Тренировка моделей, 161
 гиперпараметр, 131
 размер пакета, 134
 скорость усвоения, 135
 шаги, 132
 эпохи, 132
инвариантность, 138
 TF.Keras ImageDataGenerator,
 класс, 148
 масштабная инвариантность, 147
 трансляционная инвариантность, 140
набор данных сырой (дисковый)
 изменение размера, 157
нормализация, 116
 обзор, 116
 стандартизация, 118
обратное распространение, 108
 пакетное обратное
 распространение, 110
 предпосылки, 108
переподгонка, 119
 валидация, 119
 слежение за потерей, 123
 слои, 123
подача данных, 108
разбивка набора данных, 111
 кодирование с одним активным
 состоянием, 114
 тренировочный и тестовый
 наборы, 111
ранняя остановка, 130
сохранение/восстановление
модели, 160
 восстановление модели для
 развертывания, 160
 сохранение модельной
 архитектуры, 160
схождение, 125
сырые (дисковые) наборы данных, 150
 каталожная структура, 151

 файлы CSV, 153
 чтение изображений, 154
 фиксация состояния в контрольной
 точке, 128
Тренировка последовательная
 подача данных в модель, 470
Тренировка распределенная, 471

У

Усвоение
 классификационное, 76
 представления, 180
 преобразования, 180
 признаков, 76, 240
 репрезентативное, 170
 репрезентационное, 180
Ученик, 44, 167, 316

Ф

Фаза открытия, 519
Фаза разведки, 519
Файл значений, разделенных запятыми
(CSV), 153
Фактор сжатия, 186
Фиксация состояния в контрольной
точке, 128
Формат изображений сжатый
и сырой, 423
 гибридный подход, 426
 извлечение пакетов из сжатых
 изображений в оперативной
 памяти, 424
 извлечение пакетов с диска, 423
Формат и хранение данных, 422
 HDF5, 427
 формат изображений сжатый
 и сырой, 423
 гибридный подход, 426
 извлечение пакетов из сжатых
 изображений в оперативной
 памяти, 424
 извлечение пакетов с диска, 423
формат DICOM, 432
формат TFRecord, 434
 объект tf.Example, 435
Функция
 return A(result), 55
 return result, 55
 активационная A(), 55
 сигмоидная, 57, 66

софтмаксная, 64
шаговая, 55

Ч

Чтение изображений, 154

Ш

Шаблон абстрактной фабрики, 45
Шаблон идеоматического
конструирования, 167
 выгоды, 42
Шаблон процедурного
конструирования, 197
 ResNet, 188
 SqueezeNet, 192
 многослойный выход, 189
 нейросетевая архитектура, 167
 обработка естественного языка, 194
 понимание естественного языка, 194
 трансформер, 196
 предстержень, 179
 стержневой компонент, 170
 ResNet, 171
 ResNeXt, 176
 VGG, 169
 Xception, 178
 ученический компонент, 180
 DenseNet, 185
 ResNet, 182

Шаблон связности альтернативный, 262
DenseNet, 237
 блоки, 240
 группы, 237
 макроархитектура, 243
 переходные блоки, 243
SE-Net, 258
 архитектура, 258
 группы и блоки, 259
 связь SE, 261
Xception, 245
 архитектура, 245
 входной поток, 249
 выходной поток, 253
 свертка по глубине, 256
 срединный поток, 252
 точечная свертка, 256
Шаблон сдавливания-возбуждения-
шкалирования, 258
Шаг постоянный, 360
Шаги, 132

Э

Эквивалентность представления, 98
Эпоха, 108, 132

Я

Яркость, 150

Книги издательства «ДМК ПРЕСС»
можно купить оптом и в розницу
в книготорговой компании «Галактика»
(представляет интересы издательств
«ДМК ПРЕСС», «СОЛОН ПРЕСС», «КТК Галактика»).

Адрес: г. Москва, пр. Андропова, 38;
тел.: **(499) 782-38-89**, электронная почта: **books@aliants-kniga.ru**.
При оформлении заказа следует указать адрес (полностью),
по которому должны быть высланы книги;
фамилию, имя и отчество получателя.
Желательно также указать свой телефон и электронный адрес.
Эти книги вы можете заказать и в интернет-магазине: <http://www.galaktika-dmk.com/>.

Эндрю Ферлитш

Шаблоны и практика глубокого обучения

Главный редактор	<i>Мовчан Д. А.</i>
	<i>dmkpress@gmail.com</i>
Зам. главного редактора	<i>Сенченкова Е. А.</i>
Перевод	<i>Логунов А. В.</i>
Корректор	<i>Синяева Г. И.</i>
Верстка	<i>Чаннова А. А.</i>
Дизайн обложки	<i>Мовчан А. Г.</i>

Гарнитура PT Serif. Печать цифровая.
Усл. печ. л. 43,71. Тираж 200 экз.

Веб-сайт издательства: www.dmkpress.com

Шаблоны и практика глубокого обучения

Откройте для себя шаблоны конструирования и воспроизводимые архитектуры, которые направят ваши проекты глубокого обучения от стадии разработки к реализации.

В книге рассматриваются актуальные примеры создания приложений глубокого обучения с учетом десятилетнего опыта работы автора в этой области. Вы сэкономите часы проб и ошибок, воспользовавшись представленными здесь шаблонами и приемами. Проверенные методики, образцы исходного кода и блестящий стиль повествования позволят с увлечением освоить даже непростые навыки. По мере чтения вы получите советы по развертыванию, тестированию и техническому сопровождению ваших проектов.

Издание предназначено для инженеров машинного обучения, знакомых с Python и глубоким обучением.

Рассматриваемые темы:

- современные сверточные нейронные сети;
- шаблон конструктивного решения для сверточных нейросетевых архитектур;
- модели для мобильных устройств и устройств интернета вещей;
- крупномасштабное развертывание моделей;
- примеры приложений компьютерного зрения.

Эндрю Ферлитш — эксперт по компьютерному зрению, глубокому обучению и внедрению машинного обучения в производство в подразделении по связям с разработчиками Google Cloud AI Developer Relations.

Интернет-магазин: www.dmkpress.com

Оптовая продажа: КТК «Галактика»
books@aliens-kniga.ru



«Одна из лучших книг по глубокому обучению, которые я читал».

*Мухаммад Сохаиб Ариф,
Tek System*

«К обязательному прочтению всем, кто пытается понять все тонкости глубокого обучения и ознакомиться с лучшими образцами построения конвейера машинного обучения».

Ариэль Гаминьо, GLG

«Замечательная книга для современного профессионала глубокого обучения. Рекомендуются тем, кто хочет понять, что находится под капотом».

*Симона Сгуацца,
Университет прикладных наук и искусств Южной Швейцарии*

«Изучаете ли вы ИИ с нуля или уже обладаете некоторыми знаниями о нем, эта книга будет вашим спутником на пути к профессиональной компетенции».

Эрос Педрини, everis

ISBN 978-5-93700-113-9



9 785937 001139 >