



Куликова И. В.

Нейросети на Python

Основы ИИ и машинного обучения

- Примеры использования библиотек NumPy, PyTorch, Matplotlib, SciPy, NetworkX, TensorFlow, OpenCV, Pandas, scikit-learn, nltk
- Математические основы ИИ и машинного обучения
- Генерация изображений, создание озвучки и видео, написание текстов
- Справочник-каталог графических, текстовых, аудио-/видеонейросетей

Куликова И. В.

НЕЙРОСЕТИ

НА PYTHON

Основы ИИ и машинного обучения



"Издательство Наука и Техника"

Санкт-Петербург

Куликова И. В.

НЕЙРОСЕТИ НА PYTHON. ОСНОВЫ ИИ И МАШИННОГО ОБУЧЕНИЯ —
СПб.: Издательство Наука и Техника, 2025. — 304 с., ил.

ISBN 978-5-907592-55-1

Эта книга является практическим комплексным гидом по изучению ИИ и применению нейросетей. В ней вы найдете информацию о различных типах нейросетей, их архитектуре, принципах работы и различных возможностях использования.

Примеры использования библиотек NumPy, PyTorch, Matplotlib, SciPy, NetworkX, TensorFlow, OpenCV, Pandas, scikit-learn, nltk помогут вам лучше понять действия нейросети в реальных условиях.

Математические основы машинного обучения, с многочисленными примерами уравнений и формул на языке программирования Python, помогут понять истоки появления нейросетей с научной точки зрения.

Отдельно рассмотрено практическое применение искусственного интеллекта, описаны способы взаимодействия с нейросетями разной направленности. Это будет полезно для всех, кто желает овладеть многочисленными возможностями современных нейросетей: генерацией изображений, созданием видео, написанием текстов, созданием озвучки и т.д.

Помимо теоретической и практической частей, в книге есть ссылки на реальные нейросети, которые помогут читателям углубить свои знания и навыки в области их практического использования.

Книга обязательно станет ценным ресурсом для всех, кто хочет изучить нейросети и их применение в самых различных сферах.

Все права защищены. Никакая часть данной книги не может быть воспроизведена в какой бы то ни было форме без письменного разрешения владельцев авторских прав.

Издательство не несет ответственности за возможный ущерб, причиненный в ходе использования материалов данной книги, а также за доступность материалов, ссылки на которые вы можете найти в этой книге. На момент подготовки книги к изданию все ссылки на интернет-ресурсы были действующими.

ISBN 978-5-907592-55-1



9 785907 592551 >

Контактные телефоны издательства:

(812) 412 70 26

© Куликова И. В.

© Издательство Наука и Техника

Содержание

ГЛАВА 1. Введение в нейросети.....11

1.1. ЧТО ТАКОЕ НЕЙРОННЫЕ СЕТИ?13

На кого ориентировано это издание? 13

1.2. ИСТОРИЧЕСКИЕ ТЕНДЕНЦИИ В МАШИННОМ ОБУЧЕНИИ16

ГЛАВА 2. Математические основы машинного обучения...25

2.1. ЛИНЕЙНАЯ АЛГЕБРА28

2.1.1. Векторы, скаляры, матрицы и тензоры.....29

2.1.1.1. Примеры операций с векторами и матрицами 30

2.1.1.2. Уравнения единичной и обратной матриц..... 38

2.1.1.3. Уравнение линейной зависимости и линейной оболочки... 39

2.1.1.4. Математическое уравнение для измерения длины вектора с использованием нормы 40

2.1.1.5. Уравнение диагональной матрицы и единичного вектора.. 41

2.1.1.6. Уравнение спектрального разложения матрицы..... 43

2.1.1.7. Уравнение псевдообратной матрицы Мура-Пенроуза 44

2.1.1.8. Уравнение оператора следа..... 47

2.1.1.9. Уравнение метода главных компонент (РСА)..... 48

2.2. ТЕОРИЯ ВЕРОЯТНОСТИ И СТАТИСТИКА ДЛЯ ПОНИМАНИЯ КОНЦЕПЦИЙ ВЕРОЯТНОСТИ, РАСПРЕДЕЛЕНИЯ ВЕРОЯТНОСТИ, ОЦЕНКИ ПАРАМЕТРОВ И ПРОВЕРКИ ГИПОТЕЗ52

2.2.1. Уравнение вероятности класса (классификация)54

2.2.2. Уравнение регрессии (линейная регрессия).....58

2.2.3. Уравнение оценки параметров (оценка максимального правдоподобия)60

2.2.4. Уравнение статистического теста (тест на согласие)	61
2.2.5. Случайные величины	62
2.2.6. Распределение вероятности	63
2.2.7. Маргинальное распределение вероятности	66
2.2.8. Условная вероятность.....	68
2.2.8.1. Условная вероятность события.....	69
2.2.8.2. Зависимость переменных.....	70
2.2.8.3. Байесовский подход.....	71
2.2.8.4. Принятие решений.....	72
2.2.8.5. Марковские модели	74
2.2.9. Цепное правило.....	76
2.2.10. Независимость событий	78
2.2.11. Условная независимость событий.....	79
2.2.12. Математическое ожидание, дисперсия и ковариация	80
2.2.12.1. Математическое ожидание.....	80
2.2.12.2. Дисперсия.....	81
2.2.12.3. Ковариация	81
2.2.13. Часто встречающиеся распределения вероятности	82
2.2.13.1. Равномерное распределение	82
2.2.13.2. Нормальное (Гауссовское) распределение	83
2.2.13.3. Биномиальное распределение	84
2.2.13.4. Экспоненциальное распределение.....	85
2.2.13.5. Геометрическое распределение	85
2.2.14. Употребляемые функции (или активационные функции)...86	
2.2.14.1. Сигмоидная функция (Sigmoid).....	87
2.2.14.2. Гиперболический тангенс (Tanh)	87
2.2.14.3. ReLU (Rectified Linear Unit).....	88
2.2.14.4. Leaky ReLU.....	89
2.2.15. Непрерывные величины.....	90
2.2.15.1. Диапазон значений.....	90
2.2.15.2. Плотность вероятности	91
2.2.15.3. Функция распределения.....	92
2.2.15.4. Ожидаемое значение и дисперсия.....	93

2.2.16. Теория информации	94
2.2.16.1. Информационная энтропия	95
2.2.16.2. Избыточность и избыточное кодирование	96
2.2.16.3. Пример избыточного копирования	96
2.2.17. Каналы связи и емкость канала	97
2.2.17.1. Шум и кодирование с коррекцией ошибок	98
2.2.17.2. Информационная теорема	102
2.2.18. Структурные и вероятностные модели	103
2.2.18.1. Структурные модели	103
2.2.18.2. Вероятностные модели	105
Скрытые марковские модели (НММ)	106
Гауссовские смеси (GMM)	106
2.2.18.3. Совместное использование	107
2.3. ДИФФЕРЕНЦИАЛЬНОЕ И ИНТЕГРАЛЬНОЕ ИСЧИСЛЕНИЕ ДЛЯ ОПТИМИЗАЦИИ ФУНКЦИЙ И ОПРЕДЕЛЕНИЯ ПРОИЗВОДНЫХ, ГРАДИЕНТНОГО СПУСКА	108
2.3.1. Дифференциальное исчисление	108
2.3.2. Интегральное исчисление	109
2.3.3. Оптимизация функций	110
2.3.4. Производные	112
2.3.5. Градиентный спуск	113
2.4. ТЕОРИЯ ГРАФОВ	116
2.4.1. Графы	116
2.4.2. Деревья решений	118
2.4.2.1. Классификация	120
2.4.2.2. Регрессия	120
2.4.3. Нейронные сети	120
2.5. ОПТИМИЗАЦИЯ ДЛЯ НАХОЖДЕНИЯ РЕШЕНИЙ ЗАДАЧ, ТАКИХ КАК МИНИМИЗАЦИЯ ФУНКЦИИ ПОТЕРЬ В МАШИННОМ ОБУЧЕНИИ	122

2.5.1. Градиентный спуск	123
2.5.2. Метод наименьших квадратов (МНК)	124
2.5.3. Логистическая регрессия	125
2.6. НАСТОЯЩЕЕ И ПЕРСПЕКТИВЫ МАТЕМАТИЧЕСКИХ ОСНОВ МАШИННОГО ОБУЧЕНИЯ	127
2.7. ТИПЫ НЕЙРОСЕТЕЙ И ИХ ИСПОЛЬЗОВАНИЕ	128
2.7.1. Многослойные перцептроны	128
2.7.2. Глубокие многослойные перцептроны	131
2.7.3. Сверточные нейронные сети (CNN)	132
2.7.4. Рекуррентные нейронные сети	135
2.7.5. Генеративно-состязательные сети (GAN).....	138
2.7.6. Инструменты и библиотеки для работы с нейросетями	142
2.7.6.1. Языки программирования	143
2.7.6.2. Библиотеки и фреймворки	145
2.7.6.3. Инструменты для визуализации и обработки данных	149
ГЛАВА 3. Способы обучения машин.....	153
3.1. ОБУЧЕНИЕ С УЧИТЕЛЕМ (SUPERVISED LEARNING).....	154
3.2. ОБУЧЕНИЕ БЕЗ УЧИТЕЛЯ (UNSUPERVISED LEARNING)	156
3.3. ПОЛУОБУЧЕННОЕ ОБУЧЕНИЕ (SEMI-SUPERVISED LEARNING) ..	157
3.4. ОБУЧЕНИЕ С ПОДКРЕПЛЕНИЕМ (REINFORCEMENT LEARNING)....	158
3.5. ОБУЧЕНИЕ АКТИВНЫМ ОБРАЗОМ (ACTIVE LEARNING)	160
3.6. ГЕНЕТИЧЕСКОЕ ОБУЧЕНИЕ	162
3.7. МЕТОД ОБРАТНОГО РАСПРОСТРАНЕНИЯ ОШИБКИ (BACKPROPAGATION).....	165
3.8. ОБУЧЕНИЕ НА ОСНОВЕ КОНКУРЕНЦИИ	168
3.9. ОБУЧЕНИЕ АНСАМБЛЕМ	171
3.10. КОГНИТИВНЫЙ МЕТОД	173

3.11. ОБУЧЕНИЕ ПО ПРЕТЕНДЕНТАМ (PROTÉGÉ LEARNING)	176
3.12. ГИБРИДНОЕ ОБУЧЕНИЕ МАШИН.....	179
3.13. НАСТОЯЩЕЕ И ПЕРСПЕКТИВЫ СПОСОБОВ ОБУЧЕНИЯ МАШИН.....	182

ГЛАВА 4. Использование нейросетей. Практическое применение.....	187
--	------------

4.1. РАСПОЗНАВАНИЕ ИЗОБРАЖЕНИЙ. КЛАССИФИКАЦИЯ ИЗОБРАЖЕНИЙ. СЕГМЕНТАЦИЯ ИЗОБРАЖЕНИЙ. СОЗДА- НИЕ ИЗОБРАЖЕНИЙ, ВИДЕО	188
--	------------

4.1.1. Классификация изображений	190
4.1.2. Сегментация изображений.....	191
4.1.3. Создание изображений с помощью AI.....	194
4.1.4. Создание видео с помощью AI	197
4.1.5. Справочный материал по разделу "Практическое применение и ссылки на графические нейросети" с кратким описанием возможностей и примерами генераций изображений	201

Графические нейросети.....	201
Список графических нейросетей:	203
Видеонейросети	221

4.2. РАСПОЗНАВАНИЕ ГОЛОСА, ОЗВУЧКА, ПЕРЕВОД НА ДРУГОЙ ЯЗЫК И ИНЫЕ СПОСОБЫ	225
--	------------

4.2.1. Распознавание голоса	225
4.2.2. Озвучка	226
4.2.3. Перевод на другие языки	227
4.2.4. Анализ аудиосигналов.....	228
4.2.5. Музыкальные генеративные модели	230
4.2.6. Справочный материал по разделу "Распознавание голоса, озвучка, перевод на другой язык и иные способы"	231

Аудионейросети	231
----------------------	-----

4.3. ОБРАБОТКА ЕСТЕСТВЕННОГО ЯЗЫКА (NATURAL LANGUAGE PROCESSING, NLP)	234
4.3.1. Анализ текста	234
4.3.2. Классификация текста	235
4.3.3. Создание текста	237
4.3.4. Перевод текста	239
4.3.5. Справочный материал по разделу "Обработка естественного языка (Natural Language Processing, NLP)"	240
Текстовые нейросети	240
4.4. МЕДИЦИНА И ЗДРАВООХРАНЕНИЕ. ДИАГНОСТИКА ЗАБОЛЕВАНИЙ. РАЗРАБОТКА ЛЕКАРСТВ И ИНЫЕ СФЕРЫ ПРИМЕНЕНИЯ	247
4.4.1. Диагностика заболеваний	248
4.4.2. Разработка лекарств	249
4.4.3. Поддержка в принятии решений	251
4.4.4. Персонализированная медицина	252
4.5. ФИНАНСЫ И ЭКОНОМИКА. ПРОГНОЗИРОВАНИЕ КУРСОВ ВАЛЮТ. ОЦЕНКА РИСКОВ И ОПТИМИЗАЦИЯ ИНВЕСТИЦИЙ	254
4.5.1. Прогнозирование курсов валют	255
4.5.2. Оценка рисков	256
4.5.3. Оптимизация инвестиций	258
4.5.4. Торговля на финансовых рынках	259
4.6. ПРОЧИЕ ОБЛАСТИ ПРИМЕНЕНИЯ ИИ.....	261
4.6.1. Автономные транспортные системы	261
4.6.2. Промышленная автоматизация	262
4.6.3. Энергетика и экология	262
4.7. ПЕРСПЕКТИВЫ РАЗВИТИЯ ИИ В БЛИЖАЙШЕМ БУДУЩЕМ.....	263
Что представляют из себя на самом деле современные нейросети?	263
4.7.1. Медицинские технологии	270
4.7.2. Энергетика и экология.....	270

4.7.3. Пространственные исследования и колонизация космоса	270
--	-----

ГЛАВА 5. Этические и социальные аспекты нейросетей.

Влияние нейросетей на общество.....273

5.1. ПРОЗРАЧНОСТЬ И ОБЪЯСНИМОСТЬ	274
5.2. БЕЗОПАСНОСТЬ И ПРИВАТНОСТЬ ДАННЫХ.....	275
5.3. СПРАВЕДЛИВОСТЬ И ПРЕДВЗЯТОСТЬ	276
5.4. РАБОТА И ЗАНЯТОСТЬ	276
5.5. ЭКОНОМИЧЕСКОЕ НЕРАВЕНСТВО	276
5.6. ПОЛОЖИТЕЛЬНЫЕ СТОРОНЫ ИСПОЛЬЗОВАНИЯ НЕЙРОСЕТЕЙ. 277	
5.6.1. Автоматизация рутинных задач.....	277
5.6.2. Улучшение точности и эффективности	277
5.6.3. Повышение безопасности и комфорта.....	278
5.6.4. Предоставление персонализированных услуг	278
5.6.5. Развитие новых технологий и инноваций	279
5.7. ОТРИЦАТЕЛЬНЫЕ СТОРОНЫ ИСПОЛЬЗОВАНИЯ НЕЙРОСЕТЕЙ. 279	
5.7.1. Потеря рабочих мест	279
5.7.2. Экономическое неравенство	280
5.7.3. Предвзятость и дискриминация	280
5.7.4. Потеря контроля.....	280
5.7.5. Социальные проблемы и вызовы	281
5.8. ВОЗМОЖНЫЕ РЕШЕНИЯ И РЕГУЛИРОВАНИЕ. СОЗДАНИЕ ЭТИ- ЧЕСКОГО КОДЕКСА НЕЙРОСЕТЕЙ	281
5.8.1. Прозрачность и открытость	281
5.8.2. Этические принципы и стандарты	282
5.8.3. Обучение и образование.....	282
5.8.4. Регулирование и законодательство	283
5.8.5. Международное сотрудничество и стандартизация	283

5.9. СОЗДАНИЕ ЭТИЧЕСКОГО КОДЕКСА НЕЙРОСЕТЕЙ.....	283
5.9.1. Защита прав и интересов людей	284
5.9.2. Предотвращение негативных последствий	284
5.9.3. Установление стандартов	284
5.9.4. Повышение доверия общества	284
5.9.5. Развитие сообщества и профессионализма	284
5.9.6. Обучение	285
5.9.7. Регулирование и контроль использования нейросетей	286
5.9.7. Будущее взаимодействие нейросетей и человечества	287
5.9.8. Перспективы развития нейросетей	288
5.9.9. Нейросети и скрытые законы Вселенной	289
ЗАКЛЮЧЕНИЕ	291
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ ИНФОРМАЦИИ	295

Глава 1.

Введение в нейросети

Нейронные сети все больше проникают в нашу жизнь и становятся привычными ее атрибутами. Зачастую мы даже не осознаем, насколько часто встречаемся и взаимодействуем с ними. Одной из самых привычных для всех пользователей Интернета стала капча. Каждый из читателей легко вспомнит те самые моменты распознавания им однотипных изображений или иных действий, подтверждающих, что он не является роботом.

Мало кто из нас понимал, поспешно определяя по предлагаемым картинкам похожие предметы, выбирая символы, что мы попутно занимаемся обучением нейронной сети.




Рис. 1.1. Пример капчи

В качестве некоторых примеров применения нейросетей можно привести:

- **Искусственный интеллект:** нейросети являются основой многих систем искусственного интеллекта, таких как распознавание речи, машинный перевод, распознавание изображений с их генерацией и многое другое.
- **Медицина:** нейросети используются для диагностики заболеваний, прогнозирования исхода лечения, а также для разработки новых лекарств и методов лечения.
- **Финансы:** нейросети применяются для анализа финансовых рынков, прогнозирования цен на акции и валютного курса, а также для обнаружения мошенничества в финансовых операциях.
- **Производство:** нейросети помогают оптимизировать процессы производства, улучшать качество продукции и снижать затраты на производство.
- **Транспорт:** нейросети используются для управления транспортными системами, оптимизации маршрутов, прогнозирования пробок и улучшения безопасности на дорогах.

Это только некоторые из областей, где нейросети уже активно используются. В будущем можно ожидать еще более широкого применения нейросетей в различных областях человеческой деятельности.

1.1. Что такое нейронные сети?

На кого ориентировано это издание?

Нейронные сети — класс алгоритмов машинного обучения, вдохновленных биологическими нейронными сетями, которые составляют мозг животных и даже человека. Они состоят из слоев связанных между собой искусственных нейронов, которые обрабатывают информацию, выполняя математические операции.

Стоит отметить, что в настоящее время даже самые продвинутые нейросети едва достигают в своем «развитии» устройства мозга низших позвоночных.

К основным типам нейросетей относят:

- **Перцептроны** — используются для классификации данных, таких как распознавание изображений.
- **Рекуррентные нейронные сети (RNN)** — используются для обработки последовательностей данных, таких как текст и речь.
- **Долгосрочные краткосрочные памяти (LSTM)** — подтип RNN, который может сохранять информацию на протяжении многих шагов.
- **Сверточные нейронные сети (CNN)** — используются в задачах компьютерного зрения, таких как обнаружение объектов на изображениях.
- **Автоэнкодеры** — самообучающиеся системы, которые используются для уменьшения размерности данных.
- **Генеративно-состязательные сети (GAN)** — используются для создания новых, синтетических данных.
- **Трансформаторы** — архитектура, разработанная для обработки последовательных данных, используется в обработке естественного языка и генерации текста.
- **Нейросети для глубокого обучения** — более сложные архитектуры, такие как ResNet и VGG, используемые в компьютерном зрении.
- **Байесовские нейронные сети** — применяются для вероятностного моделирования и прогнозирования.
- **Инвариантные нейронные сети (SiN)** — используются для обнаружения объектов, которые были изменены в размере, ориентации или положении.

Данное издание претендует на научно-популярный стиль изложения материала и ориентировано на широкий круг читателей. Оно будет интересно не только студентам профильных вузов, но и всем интересующимся нейросетями.

Я выражаю благодарность авторам материалов, обозначенных в Списке использованных источников информации. Именно их материалы послужили основой данной книги. Идеи, мысли, рассуждения, цитаты, несомненно, будут присутствовать в данном издании.

Данная книга — это комплексный гид по практическому изучению и применению нейросетей. В ней вы найдете информацию о различных типах нейросетей, их архитектуре, принципах работы и различных возможностях использования. Книга также предлагает некоторые примеры, в том числе на языке программирования Python, которые помогут вам лучше понять действия нейросети в реальных условиях.



ПРИМЕЧАНИЕ. В дополнение к теоретической информации, наша книга предлагает ссылки на реальные нейросети, которые помогут читателям углубить свои знания и навыки в области практического их использования. Книга обязательно станет ценным ресурсом для всех, кто хочет изучить нейросети и их применение в сферах написания текстов, создания изображений, видео, озвучки.

Сложные для восприятия главы, например связанные с математическими основами машинного обучения, с многочисленными примерами уравнений и формул на языке программирования Python, помогут понять истоки появления нейросетей с научной точки зрения.

Разделы, посвященные практическому применению искусственного интеллекта, разъяснят способы взаимодействия с отдельными нейросетями разной направленности. Это заинтересует широкий круг читателей, желающих овладеть многочисленными возможностями современных нейросетей, связанных, например, с генерацией изображений, созданием видео и так далее.

1.2. Исторические тенденции в машинном обучении

С древних времен мыслители и ученые мечтали о создании искусственной машины, способной думать. Интересно, что на первоначальных этапах создания искусственного интеллекта удалось научить его решать многочисленные задачи, сложные для человека, но легко решаемые компьютером. Например, научить играть в шашки или шахматы. Ведь при этом используются формальные математические правила.

Сложности начались при первых попытках научить ИИ распознавать изображения лиц, устную речь. То есть именно то, что с легкостью интуитивно совершает любой человек. Обучение искусственного интеллекта решению интуитивных задач на основе постепенно приобретаемого, иерархического опыта, неформальных знаний о мире привело к бурному развитию его способностей и возможностей.

Что же такое на самом деле **машинное обучение**? Это способность ИИ самостоятельно накапливать знания и при этом создавать закономерности на их основе, используя их для последующих операций.

Исторические тенденции в машинном обучении можно условно разделить на несколько этапов.

В 1950-х и 1960-х годах машинное обучение начало развиваться с появлением первых алгоритмов, таких как метод наименьших квадратов и метод опорных векторов. В это время было разработано множество классических алгоритмов, таких как линейная регрессия и метод k-ближайших соседей.

В конце 1980-х годов с развитием компьютеров и увеличением объема данных появились новые алгоритмы, такие как деревья решений и машины опорных векторов (SVM). Однако эти алгоритмы были не очень гибкими и не могли обрабатывать нелинейные задачи.

Примерно за 30–40 предыдущих лет усилиями ученых машинное обучение стало превращаться в самостоятельную математическую дисциплину.

Постепенно, благодаря усилиям специалистов, ученых решались следующие задачи в машинном обучении:

- **Увеличение объема данных:** с развитием технологий и ростом доступности данных, объем доступных данных для машинного обучения постоянно возрастает. Это позволяет алгоритмам обучаться на больших объемах данных, что улучшает их способность к обобщению и предсказанию.
- **Улучшение алгоритмов:** алгоритмы машинного обучения также постоянно развиваются и улучшаются — от простых, таких как линейная регрессия, до более сложных, таких как глубокие нейронные сети. Они становятся все более мощными и точными.
- **Использование больших данных:** большие данные стали важным инструментом для машинного обучения. Большие объемы данных позволяют использовать алгоритмы, которые могут обрабатывать и анализировать большие объемы информации.
- **Развитие облачных вычислений:** облачные вычисления предоставляют возможность обрабатывать огромные объемы данных и использовать машинное обучение на более широкой основе. Это также позволяет компаниям и исследователям использовать машинное обучение, не заботясь о необходимости покупки и поддержки собственного оборудования.
- **Использование искусственного интеллекта:** машинное обучение является одной из ключевых технологий искусственного интеллекта. В последние годы искусственный интеллект стал более распространенным и используется в различных отраслях, таких как медицина, финансы и производство.
- **Увеличение скорости вычислений:** увеличение скорости вычислений также играет важную роль в развитии машинного обучения.
- **Более быстрые процессоры и графические процессоры (GPU)** позволяют быстрее обрабатывать и анализировать данные.

- **Расширения и интеграции:** в последнее время появилось множество расширений и интеграций машинного обучения с другими технологиями, такими как глубокое обучение, обработка естественного языка и компьютерное зрение.
- **Применение машинного обучения в реальном мире:** машинное обучение используется в самых разных сферах жизни — от прогнозирования погоды до распознавания лиц и диагностики заболеваний.
- **Этические вопросы и регулирование:** несмотря на все преимущества машинного обучения, возникают также и этические вопросы, связанные с использованием этой технологии, такие как дискриминация, конфиденциальность данных и безопасность. В связи с этим правительства и организации работают над созданием стандартов и правил использования машинного обучения.

Как уже отмечалось, с 2000-х годов нейронные сети стали активно развиваться и применяться в различных областях, таких как компьютерное зрение, обработка естественного языка, распознавание речи и других. Это было связано с появлением новых технологий, таких как графические процессоры (GPU), которые ускорили вычисления и сделали нейронные сети более доступными. Специалисты начали применять **глубокое обучение** (deep learning) **машин**, что постепенно расширило их возможности.

Ранние глубокие модели нейронных сетей применялись для «узнавания» нескольких, обычно двух, объектов в кадрированных изображениях небольшого размера. Далее размер изображений, которые возможно было обработать с помощью нейронной сети, постепенно увеличивался год от года.

Сейчас нейронные сети, предназначенные для распознавания объектов, работают с фотографиями с высоким разрешением и не требуют предварительной обработки, то есть кадрирования. Тогда как современная сеть «узнает» не менее 1000 категорий объектов.

Ежегодно проводится конкурс по распознаванию объектов — ImageNet Large Scale Visual Recognition Challenge (ILSVRC). ImageNet — это база данных изображений, организованная в соответствии с иерархией, в которой каждый узел иерархии представлен сотнями и тысячами изображений. Проект сыграл важную роль в продвижении исследований в области компьютерного зрения и глубокого обучения. Данные доступны исследователям бесплатно для некоммерческого использования (ссылка на ресурс: <https://image-net.org/>).

Знаменательным моментом стала победа с большим отрывом сверточной сети, которая принимала участие в конкурсе первый раз и сразу уменьшила частоту непопадания в первые пять (top-5 error rate) примерно с 20% до 15%. В чем суть этого показателя? Выяснилось, что сверточная сеть порождала для каждого изображения ранжированный список возможных категорий. Верная категория отсутствовала только среди первых пяти элементов данного списка в пятнадцати процентах проверочных примеров.

Сверточные сети с тех пор неизменно выигрывали в этих конкурсах, постепенно снизив частоту непопадания в первые пять до 3,5%. Это можно увидеть на графике ниже.




Рис. 1.2. Уменьшение частоты ошибок со временем¹

¹ Данные взяты из работ: Russakovsky et al, 2014 (b); He et al, 2015; Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. Москва, 2018. С. 38-39

Процесс увеличения размера моделей впечатляет. Рост популярности нейронных сетей в наше время объясняется не только прогрессом вычислительной техники, но и увеличением размеров моделей. Согласно коннекционизму, для проявления интеллекта необходимо, чтобы большое количество нейронов взаимодействовали.

В прошлом ограниченные ресурсы оборудования определяли количество соединений в искусственных нейронных сетях. Однако сегодня это скорее параметр дизайна, что позволяет создавать модели с более высокой плотностью соединений. Такие сети могут иметь количество соединений, сравнимое с нервной системой животных, от кошек до мышей. Предполагается, что «...если темпы масштабирования не ускорятся в результате внедрения новых технологий, то искусственная нейронная сеть сравняется с человеческим мозгом по числу нейронов не раньше 2050-х годов»².




Рис. 1.3. Рост размера нейронной сети со временем³

Благодаря глубокому обучению успешно развивалось и распознавание речи, хотя и не без трудностей. Если на протяжении 90-х годов XX века были достигнуты определенные успехи в этом направлении, то далее наступил период стагнации. Но начиная с 2010 года применение глубокого обучения позволило резко уменьшить частоту ошибок.

2

Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. Москва, 2018. С. 38-39

3

После добавления скрытых блоков размер нейронных сетей удваивался примерно каждые 2,4 года. Размеры биологических нейронных сетей взяты из Википедии (2015)

Не менее интересными были результаты в распознавании пешеходов и сегментации изображений. Ну а классификация дорожных знаков превзошла способности человека. Несомненно, с ростом точности усложнялись и задачи, предлагаемые нейронным сетям.

Они «научились» распознавать целые последовательности символов в изображении.

Так, например, **рекуррентная нейронная сеть** (модель LSTM) стала применяться для создания связей последовательностей с другими последовательностями. Это существенно отразилось на машинном переводе. **Нейронные машины Тьюринга** читают из ячеек памяти и пишут произвольные данные в них.

Это позволяет нейронным сетям обучаться программам на примерах желательного поведения. Если дать им примеры отсортированных и не отсортированных последовательностей, будут сформированы и отсортированы списки чисел. Фактически это начало самостоятельного программирования нейронных сетей. Пусть и в зачаточной форме.

Важным моментом применения глубокого обучения является **обучение с подкреплением**. Здесь задания выполняются в процессе обучения методом проб и ошибок. Без подсказок человека. Это позволяет, например, играть в видеоигры, выходя зачастую на уровень игрока-человека.

Большое влияние оказало глубокое обучение с подкреплением на усовершенствование робототехники. Многочисленные приложения глубокого обучения позволяют получать большую прибыль.

Они применяются такими компаниями, как Google, Microsoft, Facebook, IBM, Baidu, Apple, Adobe, Netflix, NVIDIA, NEC.

Существенный вклад глубокое обучение нейронных сетей внесло в **нейробиологию** (в визуальную обработку изображений), в **обработку иных диагностических снимков в медицине**, в отрасли, связанные с **оперированием массивами данных и прогнозированием**, а также в создание **новых лекарственных препаратов** в фармацевтической промышленности (прогноз взаимодействия молекул).

Увеличение размера моделей является важным трендом в истории глубокого обучения, обусловленным доступностью более мощной вычислительной техники и совершенствованием инфраструктуры. Этот тренд сохранится и в будущем, что будет способствовать дальнейшему развитию нейронных сетей.




Рис. 1.4. Современные дата-центры представляют собой обширные сооружения с оборудованием для хранения данных

Нейронные сети используются для решения разнообразных задач, таких как распознавание образов, классификация, регрессия, кластеризация, обработка естественного языка и многих других.

Они обладают способностью к обучению, то есть могут автоматически адаптироваться к новым данным, улучшать свои модели и делать более точные прогнозы.

Резюмируя, можно повторить, что машинное обучение продолжает развиваться, появляются новые методы, такие как глубокое обучение, обучение с подкреплением, генеративно-состязательные сети (GAN) и другие. Эти методы позволяют решать все более сложные задачи и создавать более точные модели.



Глава 2.

Математические основы машинного обучения

Математические основы машинного обучения включают в себя широкий спектр тем и методов, которые используются для разработки и анализа алгоритмов машинного обучения. Рассмотрим основные математические идеи, нужные для понимания машинного обучения, в том числе глубокого. Элементарный математический аппарат – действительно основа для самых разнообразных методов машинного обучения.

Вот некоторые из основных понятий и инструментов:

- **Линейная алгебра:** векторы, матрицы и тензоры являются основными компонентами, используемыми в большинстве алгоритмов машинного обучения, и представляют данные и функции. Они также широко используются для работы с весами и смещениями в нейронных сетях.
- **Вероятность и статистика:** вероятность и статистические методы лежат в основе многих моделей машинного обучения, включая байесовскую классификацию, регрессию и кластеризацию. Важные понятия, такие как условная вероятность, функция правдоподобия и метод максимального правдоподобия, являются ключевыми инструментами в машинном обучении.
- **Градиентный спуск:** градиент — это вектор, указывающий направление наибольшего увеличения функции, и он используется для оптимизации функций потерь в машинном обучении с помощью таких методов, как стохастический градиентный спуск (SGD) и его варианты.
- **Оптимизация гиперпараметров:** под гиперпараметрами подразумеваются параметры, которые управляют работой алгоритмов машинного обучения, например скорость обучения в SGD.

Возможно, у некоторых наших читателей при прочтении начала этой главы появится неприятие. Ведь про математику они благополучно забыли сразу после окончания школы. Тем не менее хочу подчеркнуть, что не только в основе существования нейросетей, но и всего нашего мироздания лежат математические константы. А наша реальность, по мнению многих мыслителей и ученых, — это голограмма. Пусть даже это гипотетическое утверждение.

Для большей наглядности можно вспомнить нашумевший в свое время фильм "Матрица". Помните, как главный герой, Нео, начал видеть окружающий его мир? В виде потока бегущих символов. Пусть и упрощенно, сценаристы культового фильма символически отображали математическую основу мироздания.




Рис. 2.1. Кадр из фильма "Матрица"

Настоящий математик, ученый, несомненно, подтвердит, что все процессы в нашей реальности можно отобразить языком математики.

Рассмотрим некоторые направления математических основ машинного обучения более детально. Отметим некоторые важные моменты машинного обучения, а именно важность математики для понимания принципов работы нейросетей и машинного обучения в целом, и сделаем обзор основных математических концепций, используемых в этой области.

Тем, кто пожелает глубже изучить математический аппарат нейросетей, увидеть обширные примеры уравнений в математическом выражении, связанные с обучением машин, стоит обратиться к соответствующим книгам.

В данном издании имеется лишь краткое изложение математического аппарата для нейросетей в виде уравнений и с примерами уравнений на языке Python.

2.1. Линейная алгебра

Компоненты линейной алгебры являются фундаментальными математическими объектами, широко используемыми в машинном обучении для представления и обработки данных. Они позволяют компактно описывать наборы чисел и выполнять над ними различные операции.

Далее перечислим некоторые математические компоненты и способы их применения и взаимодействия, применяемые в машинном обучении.

Что это за компоненты?

Линейная алгебра:

- векторы и матрицы — определения, операции;
- нормы векторов и матриц;
- специальные виды матриц — диагональные, единичные и т.д.;
- матричные разложения — сингулярное, собственные векторы, значения и их применение.

Аналитическая геометрия:

- уравнения прямой на плоскости и в пространстве;
- расстояния между точками, прямыми и плоскостями;
- скалярное, векторное и смешанное произведения векторов.

Анализ данных:

- статистика — среднее, медиана, стандартное отклонение, корреляция;
- теория вероятностей — распределения, условная вероятность, теорема Байеса;
- информационная теория — энтропия, взаимная информация.

Оптимизация:

- градиенты и частные производные функций;
- методы оптимизации — градиентный спуск и его варианты;
- критерии остановки и оптимальности.

Практические примеры:

- реализация основных концепций на Python с использованием NumPy, SciPy и других библиотек;
- применение линейной алгебры для представления данных;
- оценка статистических свойств наборов данных;
- оптимизация простых функций.

В следующих разделах мы кратко разберем математический аппарат, необходимый для проектирования, обучения и анализа нейросетей. Далее мы будем опираться на эти знания при изучении архитектур нейросетей и алгоритмов машинного обучения.

2.1.1. Векторы, скаляры, матрицы и тензоры

Векторы — списки чисел, которые представляют собой, например, значения различных характеристик, таких как возраст, рост и вес человека.

Скаляры — отдельные числа, которые могут представлять, например, количество денег на счету или температуру воздуха.

Матрицы — таблицы чисел, где каждое число находится в определенной позиции. В машинном обучении матрицы могут использоваться для представления связей между разными характеристиками или для хранения данных.

Тензоры — обобщение векторов и матриц на более высокие размерности. Они могут представлять сложные данные, такие как изображения или видео.

Все эти структуры помогают алгоритмам машинного обучения находить закономерности в данных и делать прогнозы или принимать решения на их основе.

2.1.1.1. Примеры операций с векторами и матрицами

Вот ряд примеров операций с векторами и матрицами в контексте машинного обучения:

1. **Умножение вектора на скаляр:** умножение каждого элемента вектора на заданное число.

Пусть у нас есть вектор v и скаляр α . Умножение вектора на скаляр представляется следующим образом:

$$v_{\text{новый}} = \alpha \times v$$

На языке программирования Python это можно сделать так:

ЛИСТИНГ 2.2. Пример умножения вектора на скаляр

```
v = [1, 2, 3] # исходный вектор
alpha = 2 # скаляр

# Умножение вектора на скаляр
new_v = [alpha * x for x in v]

print(new_v) # Вывод: [2, 4, 6]
```


2. Сложение векторов: сложение соответствующих элементов двух векторов.

Пусть у нас есть два вектора $\mathbf{v}$ и $\mathbf{w}$ с одинаковой длиной n .

Сложение соответствующих элементов двух векторов выглядит следующим образом:

$$\mathbf{v}_{\text{новый}} = \mathbf{v} + \mathbf{w}$$

На языке программирования Python это можно сделать так:

ЛИСТИНГ 2.3. Пример сложения соответствующих элементов двух векторов

```
v = [1, 2, 3] # первый вектор
w = [4, 5, 6] # второй вектор

# Сложение соответствующих элементов двух векторов

new_v = [v[i] + w[i] for i in range(len(v))]

print(new_v) # Вывод: [5, 7, 9]
```

3. Умножение матрицы на вектор: вычисление линейной комбинации столбцов матрицы с весами, заданными вектором.

Математическое уравнение: пусть у нас есть матрица $\mathbf{A}$ размером $m \times n$ и вектор $\mathbf{v}$ длиной n .

Умножение матрицы на вектор представляется следующим образом:

$$\mathbf{y} = \mathbf{A} \times \mathbf{v}$$

где $\mathbf{y}$ — новый вектор результатов.

На языке программирования Python это можно сделать с использованием библиотеки NumPy:

ЛИСТИНГ 2.4. Пример умножения матрицы на вектор

```
import numpy as np

A = np.array([[1, 2, 3], [4, 5, 6]]) # матрица
v = np.array([2, 3, 4]) # вектор

# Умножение матрицы на вектор

y = np.dot(A, v)

print(y) # Вывод: [20 47]
```

4. Умножение матриц: вычисление суммы произведений элементов строк одной матрицы на соответствующие элементы столбцов другой матрицы.

Пусть у нас есть две матрицы: **A** размером $m \times p$ и **B** размером $p \times n$.

Умножение матриц представляется следующим образом:

$$C = A \times B$$

где **C** — новая матрица результатов.

На языке программирования Python это можно сделать с использованием библиотеки NumPy:

ЛИСТИНГ 2.5. Пример умножения двух матриц

```
import numpy as np

A = np.array([[1, 2], [3, 4]]) # первая матрица
B = np.array([[5, 6], [7, 8]]) # вторая матрица

# Умножение матриц
C = np.dot(A, B)

print(C)
```

Результат на листинге 2.6 ниже представлен на языке программирования Lua.

Lua — это легковесный, скриптовый, интерпретируемый язык программирования, который широко используется в различных областях, таких как игровая разработка, встраиваемое программное обеспечение, научные вычисления и многое другое.

Lua обладает простым синтаксисом, динамической типизацией данных и поддержкой автоматического управления памятью. Одной из ключевых особенностей Lua является его высокая производительность и эффективность, что делает его популярным выбором для интеграции в другие программные системы. Lua также известен своей гибкостью и возможностью легкого расширения с помощью библиотек и модулей.

Листинг 2.6. Пример умножения матриц на языке Lua (1, 2)

```
[[19 22]
 [43 50]]
```

5. Транспонирование матрицы: переворачивание строк и столбцов матрицы.

Пусть у нас есть матрица A размером $m \times n$. Транспонирование матрицы A представляется следующим образом:

$$A^T$$

A^T — транспонированная матрица, перевернутая относительно главной диагонали.

На языке программирования Python это можно сделать с использованием библиотеки NumPy:

ЛИСТИНГ 2.7. Пример транспонирования матрицы

```
import numpy as np

A = np.array([[1, 2, 3], [4, 5, 6]]) # исходная матрица

# Транспонирование матрицы
A_transposed = np.transpose(A)

print(A_transposed)
```

Результат на языке программирования Lua:

ЛИСТИНГ 2.8. Пример транспонирования матрицы на языке Lua (1, 2)

```
[[1 4]
 [2 5]
 [3 6]]
```

- 6. Обратная матрица:** матрица, обратная данной, которая при умножении на исходную матрицу дает единичную матрицу.

Пусть у нас есть квадратная матрица A размером $n \times n$.

Обратная матрица A^{-1} — это такая матрица, которая при умножении на исходную матрицу A дает единичную матрицу I_n :

$$A \times A^{-1} = A^{-1} \times A = I_n$$

На языке программирования Python это можно сделать с использованием библиотеки NumPy, а результаты отобразить с помощью языка программирования Lua:

ЛИСТИНГ 2.9. Пример обратной матрицы (1, 2)

```
import numpy as np

A = np.array([[1, 2], [3, 4]]) # исходная матрица

# Обратная матрица
A_inv = np.linalg.inv(A)

print(A_inv)
```

Как мы видим, что произведение матрицы A на ее обратную матрицу даст единичную матрицу

Т.е., полученная матрица — это единичная матрица.

- 7. Детерминант матрицы:** числовое значение, характеризующее матрицу и используемое для определения обратной матрицы.

Пример детерминанта матрицы размером 2×2 .

Матрица:

$$A = \begin{bmatrix} a & b \\ c & d \end{bmatrix}$$

Детерминант:

$$\det(A) = ad$$

Это выражение характеризует матрицу и используется для определения ее обратной матрицы.

На языке программирования Python это можно реализовать следующим образом:

ЛИСТИНГ 2.10. Пример детерминанта матрицы

```
def determinant(matrix):
    return matrix[0][0]*matrix[1][1] - matrix[0][1]*matrix[1][0]

# Пример матрицы 2x2
matrix = [[2, 3],
          [1, 4]]

print("Детерминант матрицы:", determinant(matrix))
```

8. Вычисление скалярного произведения двух векторов: сумма произведений соответствующих элементов двух векторов.

Скалярное произведение двух векторов $\vec{a}$ и $\vec{b}$ размерности n вычисляется как сумма произведений соответствующих элементов векторов:

$$\vec{a} \cdot \vec{b} = a_1 b_1 + a_2 b_2 + \dots + a_n b_n$$

На языке программирования Python это можно реализовать следующим образом:

ЛИСТИНГ 2.11. Пример скалярного произведения двух векторов

```
def dot_product(vector1, vector2):
    result = 0
    for i in range(len(vector1)):
        result += vector1[i] * vector2[i]
    return result

# Пример векторов
vector1 = [1, 2, 3]
vector2 = [4, 5, 6]

print("Скалярное произведение векторов:", dot_product(vector1, vector2))
```

9. Вычисление матричного произведения: преобразование двух матриц в одну матрицу, где каждый элемент является скалярным произведением строки первой матрицы на столбец второй матрицы.

Вот пример вычисления матричного произведения на языке Python:

ЛИСТИНГ 2.12. Пример вычисления матричного произведения

```
# Две исходные матрицы
matrix1 = [[1, 2, 3],
            [4, 5, 6],
            [7, 8, 9]]

matrix2 = [[9, 8, 7],
            [6, 5, 4],
            [3, 2, 1]]

# Инициализация результирующей матрицы с нулевыми значениями
result = [[0, 0, 0],
           [0, 0, 0],
           [0, 0, 0]]

# Вычисление матричного произведения
for i in range(len(matrix1)):
    for j in range(len(matrix2[0])):
        for k in range(len(matrix2)):
            result[i][j] += matrix1[i][k] * matrix2[k][j]

# Вывод результирующей матрицы
for row in result:
    print(row)
```

Этот код создает исходные матрицы `matrix1` и `matrix2`, затем инициализирует результирующую матрицу `result` с нулевыми значениями. Затем он выполняет циклы для вычисления каждого элемента результирующей матрицы путем нахождения скалярного произведения строки первой матрицы на столбец второй матрицы.

Примеров использования операций с векторами, матрицами, скалярами и тензорами множество. Рассмотрим еще один.

Вот пример умножения матрицы признаков X и вектора весов w на языке Python:

ЛИСТИНГ 2.13. Пример умножения матрицы признаков на вектор весов

```
import numpy as np

# Пример данных
X = np.array([[1, 2, 3],
              [4, 5, 6],
              [7, 8, 9]])

w = np.array([0.5, 0.25, 0.75])

# Умножение матрицы признаков на вектор весов
result = np.dot(X, w)
print(result)
```

Мы рассмотрели примеры использования библиотеки NumPy на языке Python для умножения матриц и векторов, которые часто используются в машинном обучении.

Этот математический аспект линейной алгебры используется в нейронных сетях для вычисления **выхода нейронов**. В нейронных сетях каждый нейрон имеет веса, которые соответствуют параметрам модели, а входные данные представлены в виде матрицы признаков. Умножение матрицы признаков на вектор весов позволяет преобразовать входные данные и вычислить выходной сигнал нейрона.

Рассмотрим еще примеры операций с матрицами.

2.1.1.2. Уравнения единичной и обратной матриц

Приведем примеры уравнения единичной и обратной матриц на языке программирования Python с использованием библиотеки NumPy.

Единичная матрица:

ЛИСТИНГ 2.14. Создание единичной матрицы

```
import numpy as np

# Создание единичной матрицы размером 3x3
identity_matrix = np.eye(3)
print(identity_matrix)
```

Обратная матрица:

ЛИСТИНГ 2.15. Пример вычисления обратной матрицы

```
import numpy as np

# Создание матрицы
A = np.array([[1, 2, 3],
              [4, 5, 6],
              [7, 8, 9]])

# Вычисление обратной матрицы
inverse_matrix = np.linalg.inv(A)
print(inverse_matrix)
```

Эти примеры создания единичной матрицы и нахождения обратной матрицы для заданной матрицы в математическом выражении и с использованием библиотеки NumPy на языке Python.

В контексте нейросетей единичная матрица может использоваться, например, при инициализации весов нейронов. Обратная матрица может быть полезна при обучении нейросетей с использованием методов оптимизации, таких как метод наименьших квадратов или метод обратного распространения ошибки, для вычисления обновления весов.

2.1.1.3. Уравнение линейной зависимости и линейной оболочки

Линейная зависимость между векторами означает, что один из векторов может быть выражен в виде линейной комбинации других.

Линейная оболочка векторов — это множество всех линейных комбинаций этих векторов.

Вот как это можно отобразить во взаимодействии двух векторов на языке программирования Python с использованием библиотеки NumPy.

Пример вычисления линейной зависимости:

ЛИСТИНГ 2.16. Пример вычисления линейной зависимости

```
import numpy as np

# Пример данных
x = np.array([1, 2, 3])
y = np.array([2, 4, 6])

# Вычисление линейной зависимости
slope, intercept = np.polyfit(x, y, 1)
print("Угловой коэффициент (slope):", slope)
print("Смещение (intercept):", intercept)
```

Пример вычисления линейной оболочки:

ЛИСТИНГ 2.17. Пример вычисления линейной оболочки

```
import numpy as np

# Пример данных
points = np.array([[1, 1],
                   [2, 3],
                   [4, 5]])

# Вычисление линейной оболочки
hull = np.linalg.qr(points)[0]
print(hull)
```

Этот код позволяет определить уравнение линейной зависимости между векторами, а также вычислить линейную оболочку этих векторов с использованием библиотеки NumPy на языке Python.

В контексте нейросетей линейная зависимость используется для аппроксимации данных. Например, в нейронных сетях с одним нейроном линейная зависимость может быть использована для моделирования простой линейной регрессии.

Линейная оболочка может использоваться, например, для определения границы решения в задачах классификации. В нейросетях, особенно в случае многослойных персептронов, линейная оболочка может быть использована для **построения гиперплоскостей**, разделяющих классы объектов.

2.1.1.4. Математическое уравнение для измерения длины вектора с использованием нормы

Обычно в машинном обучении используются нормы, которые определяют длину вектора в пространстве.

Пример вычисления и использования евклидовой нормы для определения длины вектора в пространстве на языке Python:

ЛИСТИНГ 2.18. Пример вычисления евклидовой нормы

```
import numpy as np

# Пример вектора
v = np.array([3, 4, 5])

# Вычисление евклидовой нормы (длины вектора)
norm_v = np.linalg.norm(v)
print("Евклидова норма вектора v:", norm_v)
```

Это пример вычисления длины вектора с использованием евклидовой нормы на языке Python с помощью библиотеки NumPy.

В нейросетях **евклидова норма** часто используется для определения расстояния между двумя векторами.

Например, в методе k-ближайших соседей для классификации объектов или в алгоритме оптимизации, таком как градиентный спуск, для вычисления шага обновления весов на основе градиента функции потерь. Евклидова норма помогает определить "близость" или "различие" между векторами в многомерном пространстве.

2.1.1.5. Уравнение диагональной матрицы и единичного вектора

Диагональная матрица — это квадратная матрица, у которой все элементы вне главной диагонали равны нулю.

Вот пример вычисления диагональной матрицы и единичного вектора:

ЛИСТИНГ 2.19. Пример уравнения диагональной матрицы и единичного вектора

```
import numpy as np

# Создаем диагональную матрицу
diagonal_matrix = np.diag([3, 5, 7])

# Создаем единичный вектор
unit_vector = np.array([1, 1, 1])

# Умножаем диагональную матрицу на единичный вектор
result = np.dot(diagonal_matrix, unit_vector)

print("Результат умножения:", result)
```

Это пример вычисления диагональной матрицы и единичного вектора на языке Python с помощью библиотеки NumPy.

Диагональные матрицы и единичные векторы используются в нейросетях в различных аспектах.

Диагональные матрицы:

- **Масштабирование:** при применении масштабирования входных данных или весов нейросети можно использовать диагональные матрицы. Например, для нормализации данных или изменения весов в соответствии с их значимостью.
- **Регуляризация:** диагональные матрицы также используются в методах регуляризации, таких как L2-регуляризация, где они добавляются к градиенту функции потерь для уменьшения переобучения.

Единичные векторы:

- **Инициализация весов:** в нейросетях при инициализации весов нейронов можно использовать единичные векторы. Это помогает начать обучение с некоторого начального уровня важности для каждого признака или параметра модели.

- **Вычисление вектора градиента:** при использовании алгоритмов оптимизации, таких как метод обратного распространения ошибки, единичные векторы могут использоваться для вычисления градиента функции потерь по параметрам модели.

Эти методы помогают контролировать и оптимизировать процесс обучения нейросетей, а также улучшают обобщающую способность модели.

2.1.1.6. Уравнение спектрального разложения матрицы

Спектральное (сингулярное) разложение матрицы — это представление матрицы в виде произведения трех матриц.

Пример спектрального разложения матрицы на языке программирования Python с использованием библиотеки NumPy:

ЛИСТИНГ 2.20. Пример уравнения спектрального (сингулярного) разложения матрицы

```
import numpy as np

# Создание произвольной матрицы
A = np.array([[1, 2],
              [3, 4]])

# Сингулярное разложение
U, Sigma, Vt = np.linalg.svd(A)

# Проверка результатов
reconstructed_A = np.dot(U, np.dot(np.diag(Sigma), Vt))
print("Исходная матрица A:\n", A)
print("Восстановленная матрица A:\n", reconstructed_A)
```

Это пример использования сингулярного разложения (SVD) на языке Python с использованием библиотеки NumPy для матрицы **A**.

Спектральное (сингулярное) разложение матрицы используется в нейросетях для различных целей:

- **Уменьшение размерности данных:** при обработке больших объемов данных может возникнуть необходимость в уменьшении размерности для улучшения производительности или снижения вычислительной сложности. Спектральное разложение позволяет эффективно сжать данные, оставив только наиболее информативные компоненты.
- **Инициализация весов нейросети:** сингулярное разложение может быть использовано для инициализации весов нейросети. Используя сингулярное разложение для разложения матрицы весов на две ортогональные матрицы и диагональную матрицу сингулярных значений, можно эффективно инициализировать веса сети таким образом, чтобы ускорить обучение и улучшить сходимость.
- **Снижение переобучения:** применение сингулярного разложения для регуляризации весов нейросети может помочь уменьшить переобучение путем уменьшения степени свободы модели.
- **Анализ данных и выделение признаков:** спектральное разложение может использоваться для анализа данных и выделения наиболее важных признаков. Путем разложения матрицы признаков на компоненты, которые наилучшим образом объясняют изменчивость данных, можно выявить скрытые шаблоны или закономерности.

В целом спектральное разложение матрицы представляет собой мощный инструмент для анализа данных и оптимизации работы нейросетей, позволяя эффективно управлять размерностью данных, инициализировать веса и улучшать обобщающую способность модели.

2.1.1.7. Уравнение псевдообратной матрицы Мура-Пенроуза

Псевдообратная матрица A^+ к матрице A вычисляется с использованием сингулярного разложения (SVD) и имеет следующую формулу:

$$A^+ = V \Sigma^+ U^T$$

Где:

U — матрица из левых сингулярных векторов;

Σ^+ — псевдообратная диагональная матрица из сингулярных чисел;

V^T — транспонированная матрица из правых сингулярных векторов.

Пример на языке программирования Python с использованием библиотеки NumPy:

ЛИСТИНГ 2.21. Пример вычисления псевдообратной матрицы Мура-Пенроуза

```
import numpy as np

# Создание произвольной матрицы
A = np.array([[1, 2],
              [3, 4]])

# Сингулярное разложение
U, Sigma, Vt = np.linalg.svd(A)

# Вычисление псевдообратной матрицы
Sigma_plus = np.zeros_like(A.T)
Sigma_plus[:len(Sigma), :len(Sigma)] = np.diag(1/Sigma)
A_plus = np.dot(Vt.T, np.dot(Sigma_plus, U.T))

# Проверка результатов
reconstructed_A = np.dot(A_plus, A)
print("Исходная матрица A:\n", A)
print("Псевдообратная матрица A+:\n", A_plus)
print("Проверка: A+ * A:\n", reconstructed_A)
```

Это пример вычисления псевдообратной матрицы Мура-Пенроуза на языке Python с использованием библиотеки NumPy для матрицы A .

Уравнение псевдообратной матрицы Мура-Пенроуза (также известное как псевдообратная или обобщенная обратная матрица) используется в нейросетях для решения задач, связанных с линейным анализом данных и оптимизацией.

Основные способы использования этого уравнения:

- **Решение переопределенных систем уравнений:** при настройке параметров нейросети или решении задач регрессии может возникнуть переопределенная система уравнений, когда количество уравнений превышает количество неизвестных. В таких случаях псевдообратная матрица Мура-Пенроуза может использоваться для получения оптимального решения с использованием метода наименьших квадратов.
- **Регуляризация:** при обучении нейросетей для предотвращения переобучения или улучшения обобщающей способности модели может быть использована регуляризация с использованием псевдообратной матрицы Мура-Пенроуза. Это позволяет учесть шум в данных или предотвратить избыточную сложность модели.
- **Обратное распространение ошибки:** в методе обратного распространения ошибки, используемом для обучения многослойных нейронных сетей, псевдообратная матрица Мура-Пенроуза может быть использована для вычисления обновления весов на каждом слое сети.
- **Калибровка модели:** псевдообратная матрица Мура-Пенроуза может быть использована для калибровки модели, что позволяет улучшить ее точность и надежность путем настройки параметров или учета неопределенности в данных.

В целом уравнение псевдообратной матрицы Мура-Пенроуза представляет собой важный инструмент в нейросетях для обработки данных, оптимизации моделей и улучшения процесса обучения.

2.1.1.8. Уравнение оператора следа

Оператор следа (Tr) применяется для вычисления следа матрицы. В контексте машинного обучения след **матрицы A** может использоваться для вычисления функционала потерь или оценки качества модели. Математически уравнение выглядит так:

$$\text{Tr}(A) = \sum_{i=1}^n a_{ii}$$

где a_{ii} — это элементы главной диагонали **матрицы A**.

Пример на языке программирования Python с использованием библиотеки NumPy:

ЛИСТИНГ 2.22. Пример использования оператора следа

```
import numpy as np

# Создание произвольной матрицы
A = np.array([[1, 2, 3],
              [4, 5, 6],
              [7, 8, 9]])

# Вычисление оператора следа
trace_A = np.trace(A)

# Печать результата
print("Оператор следа матрицы A:", trace_A)
```

Это пример использования оператора следа на языке Python с использованием библиотеки NumPy для **матрицы A**.

В нейросетях уравнение оператора следа используется в различных аспектах:

- **Вычисление функций потерь:** в нейросетях, особенно в случае рекуррентных нейронных сетей (RNN) и сверточных нейронных сетей (CNN), оператор следа может использоваться для вычисления функций потерь.

Например, в случае обучения сегментации изображений оператор следа может быть использован для сравнения сегментированного изображения с исходным изображением.

- **Регуляризация:** оператор следа может быть использован для регуляризации весов нейросетей. Это помогает уменьшить переобучение модели и улучшить ее обобщающую способность.
- **Оценка качества модели:** в некоторых случаях оператор следа может использоваться для оценки качества модели, например, для вычисления расстояния между распределениями вероятностей, предсказываемыми моделью, и истинными распределениями.
- **Анализ градиентов:** оператор следа может быть использован для анализа градиентов в нейросетях. Например, он может использоваться для вычисления гессиана функции потерь по параметрам модели, что помогает в оптимизации процесса обучения и улучшении сходимости модели.
- **Управление сложностью модели:** оператор следа может использоваться для контроля сложности модели путем регуляризации или штрафа за сложность модели. Это может помочь предотвратить переобучение и улучшить обобщающую способность модели.

Таким образом, уравнение оператора следа играет важную роль в различных аспектах работы с нейросетями, помогая контролировать процесс обучения, улучшать качество модели и снижать переобучение.

2.1.1.9. Уравнение метода главных компонент (PCA)

Метод главных компонент (PCA) используется для уменьшения размерности данных путем проекции исходных данных на новое пространство признаков, где каждая компонента (главная компонента) является линейной комбинацией исходных признаков.

Далее примеры уравнения главных компонент на языке программирования Python с использованием библиотеки NumPy и библиотеки scikit-learn:

ЛИСТИНГ 2.23. Пример уравнения главных компонент

```
from sklearn.decomposition import PCA
import numpy as np

# Пример данных
X = np.array([[1, 2, 3],
              [4, 5, 6],
              [7, 8, 9]])

# Создание объекта PCA и установка количества компонент
pca = PCA(n_components=2)

# Преобразование данных
X_pca = pca.fit_transform(X)

# Получение главных компонент (собственных векторов)
principal_components = pca.components_
print("Главные компоненты (собственные векторы):")
print(principal_components)

# Получение доли объясненной дисперсии
explained_variance_ratio = pca.explained_variance_ratio_
print("Доля объясненной дисперсии:")
print(explained_variance_ratio)
```

Это пример использования метода главных компонент (PCA) на языке Python с использованием библиотеки NumPy для матрицы данных X .

Уравнение главных компонент используется в нейросетях для снижения размерности входных данных и извлечения наиболее информативных признаков.

Например, главные компоненты могут быть использованы как входные данные для нейронной сети, что позволяет сократить количество параметров

модели и улучшить ее обобщающую способность. Кроме того, уравнение главных компонент может быть использовано для предобработки данных перед их подачей на вход нейросети, что помогает улучшить производительность и сходимость модели.



ПРИМЕЧАНИЕ. Таким образом, компоненты линейной алгебры играют очень важную роль в нейросетях. Они используются для описания структуры моделей, вычисления выходных данных и обновления параметров модели в процессе обучения.

Векторы весов используются для представления параметров модели, таких как веса связей между нейронами в разных слоях нейросети. Входные данные также представляются в виде векторов, где каждый элемент вектора может представлять один признак или атрибут входных данных.

Матрицы весов, определяющие связи между нейронами различных слоев нейросети, представляются в виде матриц. Результаты промежуточных вычислений, такие как активации нейронов в скрытых слоях или выходы нейросети, могут быть представлены в виде матриц.

Операции линейной алгебры, такие как **умножение матриц**, являющиеся одной из основных операций в нейронных сетях, используются для вычисления выхода каждого слоя на основе входных данных и соответствующих весов. Сложение векторов может использоваться, например, при добавлении смещения к выходу слоя.

Различные разложения матриц, такие как сингулярное разложение (SVD) или разложение Холецкого, могут использоваться для анализа и упрощения матриц в нейронных сетях.

Компоненты линейной алгебры в нейросетях используются для описания структуры моделей, вычисления выходных данных и обновления параметров модели в процессе обучения.

Резюмируем все вышеизложенное.

Операции с **векторами, скалярами, тензорами** и другими компонентами **линейной алгебры** играют ключевую роль в создании, программировании и обучении нейронных сетей по следующим причинам:

- **Представление данных:** векторы и тензоры используются для представления входных данных (например, изображений, звуковых сигналов) и соответствующих меток (например, классов объектов на изображениях) в формате, понятном для нейронных сетей.
- **Вычисления:** операции линейной алгебры, такие как умножение матриц, добавление векторов и тензоров, необходимы для эффективного выполнения преобразований данных внутри нейронных сетей. Например, слои нейронных сетей часто применяют линейные преобразования к входным данным с использованием матричного умножения.
- **Оптимизация:** при обучении нейронных сетей процесс оптимизации, такой как стохастический градиентный спуск, требует вычисления градиентов функции потерь по параметрам модели. Эти вычисления часто основаны на производных функций, которые используют операции линейной алгебры.
- **Анализ результатов:** линейная алгебра позволяет анализировать и интерпретировать результаты нейронных сетей. Например, с помощью сингулярного разложения можно выделить наиболее информативные признаки изображений, а с помощью кластерного анализа можно выявить структуру в данных.

Таким образом, понимание операций линейной алгебры и их применение в программировании помогают создавать эффективные и мощные нейронные сети, способные обучаться на больших объемах данных и решать разнообразные задачи в машинном обучении и глубоком обучении.

2.2. Теория вероятности и статистика для понимания концепций вероятности, распределения вероятности, оценки параметров и проверки гипотез

Теория вероятностей и теория информации являются неотъемлемыми компонентами в машинном обучении. Это связано с тем, что в машинном обучении часто приходится иметь дело с данными, содержащими неопределенность или стохастичность.

Неопределенность и стохастичность могут возникать из различных источников. Уже в 1980-х годах были предложены теоретические аргументы в пользу использования вероятностных методов для количественной оценки неопределенности.

Многие из этих аргументов были представлены в работе Перла (1988) или вдохновлены ею. Практически во всех областях знания необходимо уметь рассуждать в условиях неопределенности. За исключением математических утверждений, которые являются истинными по определению, сложно найти высказывание, которое было бы абсолютно верным, или событие, которое произойдет с полной гарантией.

Существует три основных источника неопределенности:

- 1. Стохастичность, присущая моделируемой системе.** Например, в квантовой механике динамика субатомных частиц описывается в вероятностных терминах. Также можно создать теоретические сценарии с постулированной случайной динамикой, например гипотетическую карточную игру, где карты перетасовываются случайно.
- 2. Неполнота наблюдаемых данных.** Даже если система является детерминированной, она может казаться стохастической, если мы не можем

наблюдать все переменные, описывающие ее поведение. Например, в парадоксе Монти Холла результат выбора участника игры остается неопределенным из-за неполноты информации о том, что находится за выбранными дверями.

- 3. Неполнота модели.** Если используется модель, которая не учитывает часть доступной информации, это может привести к недостоверным предсказаниям. Например, если робот, способный точно определять положение объектов, дискретизирует пространство для прогнозирования положений объектов в будущем, то этот процесс сделает информацию о положении объектов неопределенной.

Зачастую более практично использовать простые неопределенные правила, чем сложные определенные, даже если истинное правило детерминировано и система моделирования способна его адекватно представить.

Хотя теория вероятностей изначально была разработана для анализа частоты событий, она также может применяться к событиям, которые не могут быть повторены.

Вероятность в таких случаях означает степень уверенности в возможном исходе, и это называется байесовской вероятностью. Вероятность можно рассматривать как обобщение логики на условия неопределенности. Логика позволяет определить, истинно ли высказывание в зависимости от истинности других высказываний. Теория вероятностей же позволяет определить правдоподобие высказывания при условии правдоподобия других высказываний.

- **Вероятность** — это мера того, насколько вероятно возникновение какого-то события. Например, вероятность того, что завтра будет солнечно, или вероятность того, что пользователь кликнет на определенную рекламу.
- **Распределение вероятности** — это способ описать, как вероятность распределена между различными исходами события. Например, у нас может быть распределение вероятности для возраста пользователей на сайте, где мы можем увидеть количество пользователей в определенном возрастном диапазоне.

- **Оценка параметров** — это процесс определения значений параметров модели на основе данных. Например, если у нас есть данные о домах, то мы можем использовать оценку параметров для определения коэффициентов, которые лучше всего соответствуют этим данным и помогут предсказать цены на недвижимость.
- **Проверка гипотез** — это процесс определения, насколько вероятно то, что какой-то эффект действительно существует в данных, а не является случайным. Например, мы можем проверить гипотезу о том, что средняя зарплата программистов выше, чем средняя зарплата в других профессиях.

Эти концепции важны в **машинном обучении**, потому что они помогают алгоритмам понимать и использовать данные для прогнозирования, классификации или принятия решений.

Далее рассмотрим примеры уравнений на языке Python с использованием библиотек NumPy и scikit-learn, связанных с теорией вероятности и статистикой в контексте машинного обучения.

2.2.1. Уравнение вероятности класса (классификация)

Это уравнение широко используется в алгоритмах классификации, таких как наивный байесовский классификатор. Также уравнение вероятности класса в нейросетях обычно используется для оценки вероятности принадлежности объекта к определенному классу.

Приведем пример уравнения вероятности класса в математическом выражении и его реализации на языке Python в контексте наивного байесовского классификатора.

Математическое выражение:

пусть у нас есть признаки $X = \{x_1, x_2, \dots, x_n\}$, а классы обозначены как $C = \{c_1, c_2, \dots, c_k\}$.

Тогда уравнение вероятности класса c_j для заданного набора признаков X выглядит следующим образом в контексте наивного байесовского классификатора:

$$P(c_j | X) = \frac{P(X|c_j) \cdot P(c_j)}{P(X)}$$

Пример на Python:

ЛИСТИНГ 2.24. Пример расчета вероятности класса на языке Python в контексте наивного байесовского классификатора

```
from sklearn.datasets import load_iris
from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import GaussianNB
from sklearn.metrics import accuracy_score

# Загрузка датасета Iris
iris = load_iris()
X, y = iris.data, iris.target

# Разделение данных на обучающий и тестовый наборы
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3,
                                                    random_state=42)

# Создание и обучение модели наивного байесовского
классификатора
model = GaussianNB()
model.fit(X_train, y_train)

# Предсказание классов для тестового набора
y_pred = model.predict(X_test)

# Оценка точности классификации
accuracy = accuracy_score(y_test, y_pred)
print("Accuracy:", accuracy)
```

В этом примере используется библиотека `scikit-learn` для создания и обучения модели наивного байесовского классификатора на датасете `Iris`. После обучения модели оценивается ее точность на тестовом наборе данных.

Приведем еще пример математического выражения вероятности класса в контексте нейронных сетей.

Математическое выражение:

предположим, у нас есть нейронная сеть, обученная для задачи классификации с несколькими классами. Пусть $P(y_i|x)$ обозначает вероятность принадлежности объекта x к классу y_i . Тогда уравнение вероятности класса y_i можно записать как:

$$P(y_i|x) = \frac{\exp(z_i)}{\sum_{j=1}^N \exp(z_j)}$$

где z_i — это выход нейронной сети, соответствующий классу y_i , а N — общее количество классов.

Теперь пример на языке программирования Python для создания наивного байесовского классификатора:

ЛИСТИНГ 2.25. Пример создания наивного байесовского классификатора

```
import numpy as np

class NaiveBayesClassifier:
    def fit(self, X_train, y_train):
        self.classes = np.unique(y_train)
        self.class_probs = {}
        self.feature_probs = {}

        for c in self.classes:
            X_c = X_train[y_train == c]
            self.class_probs[c] = len(X_c) / len(X_train)
            self.feature_probs[c] = {}
            for i in range(X_train.shape[1]):
                self.feature_probs[c][i] = {}
                for value in np.unique(X_train[:, i]):
                    self.feature_probs[c][i][value] = (np.sum(X_c[:, i] == value) + 1) / (len(X_c) + len(np.unique(X_train[:, i])))

    def predict(self, X_test):
        predictions = []
```

```

        for x in X_test:
            probs = {c: np.log(self.class_probs[c]) for c in self.
classes}
            for c in self.classes:
                for i, value in enumerate(x):
                    probs[c] += np.log(self.feature_probs[c][i].
get(value, 1e-5)) # laplace smoothing
                predictions.append(max(probs, key=probs.get))
            return predictions

# Пример использования
X_train = np.array([[1, 'S'],
                    [1, 'M'],
                    [1, 'M'],
                    [1, 'S'],
                    [1, 'S'],
                    [2, 'S'],
                    [2, 'M'],
                    [2, 'M'],
                    [2, 'L'],
                    [2, 'L'],
                    [3, 'L'],
                    [3, 'M'],
                    [3, 'M'],
                    [3, 'L'],
                    [3, 'L']])
y_train = np.array([0, 0, 1, 1, 0, 0, 0, 1, 1, 1, 1, 1, 1, 1, 0]) #
0 - отрицательный класс, 1 - положительный класс

X_test = np.array([[2, 'S'],
                   [3, 'M']])

nb_classifier = NaiveBayesClassifier()
nb_classifier.fit(X_train, y_train)
predictions = nb_classifier.predict(X_test)
print("Predictions:", predictions)

```

В этом примере создается простой наивный байесовский классификатор для задачи классификации текста, где входные данные представляют собой матрицу признаков X и соответствующие метки классов y .

Еще модель наивного байесовского классификатора можно сделать с помощью softmax-функции, которая преобразует выходы нейронной сети в вероятностное распределение по классам. В конечном итоге для каждого класса получается вероятность его принадлежности, а сумма всех вероятностей равна 1.

ЛИСТИНГ 2.26. Пример уравнения вероятности класса (классификация)

```
from sklearn.naive_bayes import GaussianNB

# Создание модели наивного байесовского классификатора
model = GaussianNB()

# Обучение модели на обучающих данных
model.fit(X_train, y_train)

# Предсказание вероятности принадлежности к классам для
тестовых данных
probabilities = model.predict_proba(X_test)

# Вероятность принадлежности к классу 1 для первых 10 объектов
тестовых данных
print(probabilities[:10, 1])
```

Резюмируем: уравнения вероятности класса широко используются в создании и обучении нейронных сетей для задач классификации, таких как распознавание образов, анализ текста или определение категорий. Они помогают модели оценивать вероятность принадлежности объекта к различным классам, что позволяет принимать более информированные решения на основе этих вероятностей.

В частности, методика максимального правдоподобия и байесовский подход используются для обучения моделей с учетом вероятностных закономерностей в данных.

2.2.2. Уравнение регрессии (линейная регрессия)

Уравнение регрессии в нейросетях необходимо для прогнозирования непрерывного значения на основе входных данных. В нейронной сети обычно используются слои с активацией, которые обеспечивают нелинейную способность модели адаптироваться к сложным зависимостям в данных.

После обучения нейросети ее можно использовать для предсказания значений на новых данных, применяя уравнение регрессии к входным признакам и вычисляя соответствующий выход.

Пример линейной регрессии на языке программирования Python:

ЛИСТИНГ 2.27. Уравнение линейной регрессии с использованием библиотеки *scikit-learn*

```
from sklearn.linear_model import LinearRegression

# Создание модели линейной регрессии
model = LinearRegression()

# Обучение модели на обучающих данных
model.fit(X_train, y_train)

# Предсказание значений для тестовых данных
predictions = model.predict(X_test)

# Вывод предсказанных значений для первых 10 объектов тестовых
данных
print(predictions[:10])
```

Это уравнение линейной регрессии использует метод наименьших квадратов для поиска оптимальных коэффициентов, а затем использует эти коэффициенты для предсказания целевых значений для новых данных.

Резюмируем: уравнение линейной регрессии играет важную роль в контексте нейронных сетей как базовая модель для обработки данных и предсказания значений. В нейросетях оно часто используется как один из слоев (например, полносвязный слой) для преобразования входных данных в промежуточное представление.

Это позволяет модели изучать нелинейные зависимости между входными и выходными данными, улучшая ее способность к предсказанию. Таким образом, уравнение линейной регрессии является важным компонентом в процессе обучения нейросетей.

2.2.3. Уравнение оценки параметров (оценка максимального правдоподобия)

Вот пример на языке Python, где мы оцениваем параметры линейной регрессии с использованием метода максимального правдоподобия:

ЛИСТИНГ 2.28. Уравнение оценки параметров с использованием метода максимального правдоподобия

```
import numpy as np
from scipy.optimize import minimize

# Генерируем случайные данные для линейной регрессии
np.random.seed(0)
X = 2 * np.random.rand(100, 1)
y = 4 + 3 * X + np.random.randn(100, 1)

# Определяем функцию правдоподобия для линейной регрессии
def likelihood(parameters):
    intercept, slope = parameters
    y_pred = intercept + slope * X
    error = y - y_pred
    likelihood_values = (1 / np.sqrt(2 * np.pi)) * np.exp(-0.5 *
(error ** 2))
    return -np.prod(likelihood_values)

# Используем метод максимального правдоподобия для оценки
параметров
initial_guess = [0, 0]
# Начальное предположение для параметров
result = minimize(likelihood, initial_guess, method='Nelder-Mead')

# Получаем оцененные параметры
intercept_mle, slope_mle = result.x

print("Оценка параметра intercept:", intercept_mle)
print("Оценка параметра slope:", slope_mle)
```

Этот код генерирует случайные данные для линейной регрессии, а затем оценивает параметры (перехват и наклон) с использованием метода максимального правдоподобия.

Резюмируем: в нейросетях уравнение оценки параметров, или оценка максимального правдоподобия, используется в процессе обучения модели. Это уравнение формулируется таким образом, чтобы максимизировать вероятность получения наблюдаемых данных при заданных параметрах модели. В процессе обучения нейросети параметры (веса и смещения) изменяются с помощью методов оптимизации, таких как градиентный спуск, чтобы максимизировать оценку максимального правдоподобия. Это позволяет модели наилучшим образом соответствовать тренировочным данным и делать более точные прогнозы на новых данных.

2.2.4. Уравнение статистического теста (тест на согласие)

ЛИСТИНГ 2.29. Уравнение статистического теста на согласие (например, тест хи-квадрат)

```
from scipy.stats import chi2_contingency

# Пример данных для теста на согласие
observed = [[10, 15, 20],
             [5, 10, 15]]

# Выполнение теста хи-квадрат
chi2, p_value, dof, expected = chi2_contingency(observed)

print("Статистика хи-квадрат:", chi2)
print("p-значение:", p_value)
print("Степени свободы:", dof)
print("Ожидаемые частоты:", expected)
```

Это уравнение выполняет статистический тест на согласие с использованием библиотеки SciPy для категориальных данных, используя тест хи-квадрат. Результатом является статистика хи-квадрат, p-значение, степени свободы и ожидаемые частоты.

В примере данные представлены в виде таблицы сопряженности (например, двух различных методов измерений для трех групп объектов), и тест хи-квадрат используется для проверки, есть ли статистическое между этими методами измерений.

Резюмируем: в нейросетях уравнение статистического теста, такого как тест на согласие, может использоваться для оценки того, насколько нейросеть соответствует ожидаемым статистическим распределениям данных. Например, после обучения нейросети на наборе данных можно применить тест на согласие для проверки того, насколько распределение выходов нейросети соответствует некоторому ожидаемому распределению, такому как нормальное или равномерное. Это может быть полезным для оценки адекватности модели или выявления аномалий в ее поведении.

2.2.5. Случайные величины

В машинном обучении случайные величины играют важную роль, особенно в статистических методах и вероятностных моделях.

Случайная величина — это переменная, которая может принимать различные значения в зависимости от исхода случайного эксперимента. В контексте машинного обучения случайные величины используются для моделирования неопределенности и стохастичности в данных и процессах.

Вот несколько примеров использования случайных величин в машинном обучении:

- **Генерация случайных выборок:** случайные величины используются для генерации случайных выборок данных, которые могут быть использованы для обучения и тестирования моделей машинного обучения.
- **Вероятностные модели:** вероятностные модели могут описывать зависимости между случайными величинами в данных. Например, вероятностные графические модели используются для моделирования сложных зависимостей между признаками и целевой переменной.
- **Байесовский подход:** в байесовском машинном обучении случайные величины используются для представления неопределенности в параметрах модели. Байесовские методы позволяют оценивать вероятностные распределения параметров модели на основе данных и априорных предположений.

- **Стохастический градиентный спуск:** в оптимизации моделей машинного обучения, таких как нейронные сети, используется стохастический градиентный спуск, который работает с оценками градиента функции потерь на основе случайных подвыборок данных.

Дополнительно:

- **Инициализация весов:** при создании нейронных сетей начальные веса могут быть инициализированы случайными значениями. Это помогает избежать симметрии между нейронами и способствует лучшей сходимости модели в процессе обучения.
- **Выбор случайных примеров:** для обучения нейросетей часто используются стохастические методы оптимизации, такие как стохастический градиентный спуск (SGD). В этом случае случайные величины используются для выбора случайных подмножеств обучающих данных на каждой итерации, что помогает модели избегать застревания в локальных минимумах.
- **Регуляризация:** случайные величины могут быть также использованы в методах регуляризации, таких как Dropout. Этот метод случайным образом отключает нейроны на каждой итерации обучения, что помогает сети изучать более устойчивые и обобщающие признаки.
- **Шум:** добавление случайного шума к данным или внутренним представлениям сети может помочь в улучшении обобщающей способности модели и снижении переобучения.

Таким образом, случайные величины играют ключевую роль в обучении и оптимизации нейронных сетей, помогая им изучать сложные зависимости в данных и создавать более эффективные и обобщающие модели.

2.2.6. Распределение вероятности

Распределение вероятности — это способ описания возможных значений и вероятностей их появления для случайной величины.

В контексте машинного обучения **распределения вероятности** играют ключевую роль в моделировании неопределенности, оценке вероятностей событий и создании статистических моделей данных.

Вот несколько основных аспектов распределений вероятности в машинном обучении:

- **Параметрические распределения:** в некоторых случаях предполагается, что данные подчиняются определенному параметрическому распределению, такому как нормальное, Бернулли, равномерное и другие. Эти распределения часто используются для моделирования случайных переменных в статистических методах машинного обучения.
- **Непараметрические распределения:** в других случаях распределения вероятности могут быть оценены непараметрически, то есть без явного предположения о форме распределения. Непараметрические методы могут быть полезны, когда данные не соответствуют известным параметрическим моделям.
- **Оценка параметров распределения:** в задачах машинного обучения, где используются параметрические модели, часто требуется оценка параметров распределения на основе имеющихся данных. Это может быть выполнено с помощью метода максимального правдоподобия или байесовских методов.
- **Вероятностные модели:** распределения вероятности широко используются для построения вероятностных моделей данных. Эти модели могут использоваться для прогнозирования, классификации, кластеризации и других задач машинного обучения.
- **Оценка неопределенности:** распределения вероятности также используются для оценки неопределенности в предсказаниях моделей. Например, байесовские методы машинного обучения позволяют моделировать неопределенность в параметрах модели и делать вероятностные прогнозы.

Вот пример использования распределения вероятности на языке программирования Python с использованием библиотеки PyTorch для нейронных сетей:

ЛИСТИНГ 2.30. Пример использования распределения вероятности

```
import torch
import torch.nn as nn
import torch.optim as optim
import numpy as np

# Создание нейронной сети
class NeuralNetwork(nn.Module):
    def __init__(self):
        super(NeuralNetwork, self).__init__()
        self.fc1 = nn.Linear(784, 128) # Полносвязный слой с 784
        входами и 128 выходами
        self.fc2 = nn.Linear(128, 10) # Полносвязный слой с 128
        входами и 10 выходами

    def forward(self, x):
        x = torch.flatten(x, 1) # Преобразование входного изображения
        в одномерный тензор
        x = torch.relu(self.fc1(x)) # Применение ReLU к выходу
        первого слоя
        x = self.fc2(x) # Выходной слой без функции активации (после
        него будет применена softmax)
        return x

# Создание экземпляра модели
model = NeuralNetwork()

# Определение функции потерь и оптимизатора
criterion = nn.CrossEntropyLoss() # Функция потерь Cross Entropy
optimizer = optim.SGD(model.parameters(), lr=0.01) # Стохастический
градиентный спуск

# Генерация случайных входных данных (например, изображений)
input_data = torch.randn(10, 28, 28) # Генерация 10 случайных
изображений размером 28x28

# Прямой проход
outputs = model(input_data)

# Вычисление потерь
labels = torch.randint(0, 10, (10,)) # Случайные метки классов для
примеров
loss = criterion(outputs, labels)
```

```
# Обратное распространение ошибки и обновление весов
optimizer.zero_grad()
loss.backward()
optimizer.step()
```

В этом примере мы создаем нейронную сеть с двумя полносвязными слоями. После прямого прохода мы вычисляем потери с помощью функции потерь Cross Entropy и обновляем веса с помощью оптимизатора стохастического градиентного спуска (SGD). Все операции выполняются на основе тензоров PyTorch, которые представляют случайные величины и вычисления в нейронных сетях.

Резюмируем: в целом распределения вероятности являются важным инструментом в машинном обучении, который помогает моделировать и понимать стохастическую природу данных, а также оценивать неопределенность в предсказаниях моделей.

2.2.7. Маргинальное распределение вероятности

Маргинальное распределение вероятности в контексте машинного обучения относится к распределению вероятностей одной или нескольких случайных переменных, полученным путем интегрирования или суммирования по всем возможным значениям других переменных.

В машинном обучении маргинальные распределения играют важную роль при работе с многомерными данными и вероятностными моделями.

Вот несколько ключевых моментов, связанных с маргинальными распределениями:

- **Работа с многомерными данными:** когда имеется многомерный набор данных, состоящий из нескольких переменных, маргинальные распределения позволяют анализировать каждую переменную отдельно, игнорируя остальные. Например, если у нас есть двумерное распределение

вероятности, то маргинальное распределение каждой переменной представляет собой вероятностное распределение этой переменной, интегрированное или суммированное по всем возможным значениям другой переменной.

- **Вычисление статистик:** маргинальные распределения используются для вычисления различных статистик, таких как среднее, дисперсия, квантили и т.д., для каждой отдельной переменной в многомерных данных. Это позволяет понять особенности распределения каждой переменной независимо от остальных.
- **Вероятностные модели:** в машинном обучении вероятностные модели часто используют многомерные распределения вероятности для описания зависимостей между переменными. Маргинальные распределения могут быть использованы для оценки и анализа вероятностей каждой переменной в модели, а также для выполнения прогнозов и классификации.
- **Снижение размерности:** маргинальные распределения могут быть использованы для снижения размерности данных путем удаления менее значимых переменных или переменных, которые слабо коррелируют с целевой переменной. Это позволяет упростить моделирование и улучшить производительность моделей машинного обучения.

Вот пример использования маргинального распределения вероятности на языке программирования Python с использованием библиотеки PyTorch:

ЛИСТИНГ 2.31. Пример маргинального распределения вероятности

```
import torch
import torch.nn as nn
import numpy as np

# Создание нейронной сети
class NeuralNetwork(nn.Module):
    def __init__(self):
        super(NeuralNetwork, self).__init__()
        self.fc1 = nn.Linear(10, 5) # Полносвязный слой с 10 входами
и 5 выходами
        self.fc2 = nn.Linear(5, 1)  # Полносвязный слой с 5 входами
и 1 выходом
```

```

def forward(self, x):
    x = torch.relu(self.fc1(x)) # Применение ReLU к выходу
    # первого слоя
    x = self.fc2(x) # Выходной слой без функции активации
    return x
# Создание экземпляра модели
model = NeuralNetwork()
# Генерация случайных входных данных (например, признаков)
input_data = torch.randn(100, 10) # Генерация 100 случайных примеров
# с 10 признаками каждый
# Прямой проход
outputs = model(input_data)
# Вычисление маргинального распределения вероятности
marginal_distribution = torch.sigmoid(outputs) # Применение
# сигмоидной функции для получения вероятности

# Вывод результатов
print(marginal_distribution)

```

В этом примере мы создаем нейронную сеть с двумя полносвязными слоями и применяем ее к случайным входным данным.

После прямого прохода мы вычисляем маргинальное распределение вероятности, используя сигмоидную функцию активации для получения вероятности на выходе. В результате получаем маргинальное распределение вероятности для каждого примера во входных данных.

Резюмируем: таким образом, маргинальные распределения вероятности являются важным инструментом в машинном обучении, который помогает анализировать и работать с многомерными данными, оценивать вероятностные модели и упрощать моделирование путем снижения размерности данных.

2.2.8. Условная вероятность

Условная вероятность — это вероятность того, что какое-то событие произойдет при условии, что другое событие уже произошло.

В контексте машинного обучения условная вероятность играет важную роль при моделировании зависимостей между переменными и принятии решений на основе имеющейся информации.

Вот несколько ключевых аспектов условной вероятности в машинном обучении.

2.2.8.1. Условная вероятность события

Условная вероятность события определяется как отношение вероятности одновременного выполнения одного события к вероятности другого события.

Формула условной вероятности на языке Python выглядит следующим образом:

ЛИСТИНГ 2.32. Пример формулы условной вероятности

```
# Функция для вычисления условной вероятности
def conditional_probability(p_xy, p_x):
    return p_xy / p_x

# Пример значений вероятностей
p_x_y = 0.8 # Вероятность наступления события X и Y
p_x = 0.6   # Вероятность наступления события X

# Вычисление условной вероятности
p_y_given_x = conditional_probability(p_x_y, p_x)
print("Условная вероятность принадлежности к классу Y при заданных признаках X:")
print(p_y_given_x)
```

Эта формула используется для оценки вероятности принадлежности к классу Y при заданных признаках X, что часто встречается в задачах классификации в машинном обучении.

2.2.8.2. Зависимость переменных

Условная вероятность позволяет моделировать зависимость между переменными. Например, в задаче классификации условная вероятность может использоваться для оценки вероятности принадлежности объекта к определенному классу при условии его характеристик.

Вот пример зависимости переменных условной вероятности в контексте нейросетей на языке программирования Python с использованием библиотеки PyTorch:

ЛИСТИНГ 2.33. Пример зависимости переменных условной вероятности на языке программирования Python с использованием библиотеки PyTorch

```
import torch
import torch.nn as nn
import numpy as np

# Создание нейронной сети
class ConditionalProbabilityNN(nn.Module):
    def __init__(self):
        super(ConditionalProbabilityNN, self).__init__()
        self.fc1 = nn.Linear(2, 10) # Полносвязный слой с 2 входами
и 10 выходами
        self.fc2 = nn.Linear(10, 1) # Полносвязный слой с 10
входами и 1 выходом
    def forward(self, x):
        x = torch.relu(self.fc1(x)) # Применение ReLU к выходу
первого слоя
        x = torch.sigmoid(self.fc2(x)) # Применение сигмоидной
функции к выходу второго слоя
        return x

# Создание экземпляра модели
model = ConditionalProbabilityNN()

# Генерация случайных входных данных (например, признаков)
input_data = torch.randn(100, 2)

# Генерация 100 случайных примеров с 2 признаками каждый

# Прямой проход
outputs = model(input_data)
```



```
# Вывод результатов
print(outputs)
```

В этом примере мы создаем нейронную сеть с двумя полносвязными слоями и применяем ее к случайным входным данным, представляющим две переменные. После прямого прохода мы получаем выходные значения, которые представляют условные вероятности, зависящие от входных переменных. В данном примере мы используем сигмоидную функцию активации на выходном слое, чтобы получить вероятности в диапазоне от 0 до 1.

2.2.8.3. Байесовский подход

Байесовский подход в машинном обучении основан на использовании условных вероятностей для обновления априорных знаний о параметрах модели на основе имеющихся данных. Это позволяет строить более точные и адаптивные модели, учитывая текущую информацию.

Вот пример байесовского подхода с использованием условных вероятностей на языке программирования Python:

ЛИСТИНГ 2.34. Пример байесовского подхода с использованием условных вероятностей

```
import numpy as np

# Генерация случайных данных
# Допустим, у нас есть два бинарных признака: X1 и X2, и мы хотим
# предсказать целевую переменную Y
# Вектор X1
X1 = np.array([0, 1, 0, 1, 0, 1, 0, 1, 1, 0])
# Вектор X2
X2 = np.array([0, 0, 1, 1, 0, 0, 1, 1, 0, 1])
# Вектор целевой переменной Y
Y = np.array([0, 0, 1, 1, 0, 1, 0, 1, 1, 0])
```

```

# Подсчет условных вероятностей P(Y|X1, X2)
# Для этого мы считаем количество совпадений для каждой комбинации
значений X1, X2 и Y
# Затем делим количество совпадений на общее количество случаев для
каждой комбинации X1, X2
def conditional_probabilities(X1, X2, Y):
    conditional_probs = {}
    for i in range(2): # Цикл по значениям X1 (0 или 1)
        for j in range(2): # Цикл по значениям X2 (0 или 1)
            for k in range(2): # Цикл по значениям Y (0 или 1)
                # Считаем количество случаев, когда X1=x1, X2=x2 и Y=y
                count = np.sum((X1 == i) & (X2 == j) & (Y == k))
                # Считаем общее количество случаев, когда X1=x1 и X2=x2
                total = np.sum((X1 == i) & (X2 == j))
                # Вычисляем условную вероятность P(Y=k|X1=i, X2=j)
                conditional_probs[(i, j, k)] = count / total
    return conditional_probs

# Вывод условных вероятностей
conditional_probs = conditional_probabilities(X1, X2, Y)
for key, value in conditional_probs.items():
    print(f"P(Y={key[2]}|X1={key[0]}, X2={key[1]}) = {value:.2f}")

```

Этот код вычисляет условные вероятности $P(Y|X1, X2)$ для всех возможных комбинаций значений $X1$, $X2$ и Y на основе данных $X1$, $X2$ и Y .

Затем он выводит эти вероятности.

2.2.8.4. Принятие решений

Условные вероятности могут быть использованы для принятия решений в условиях неопределенности. Например, в задачах классификации можно выбрать класс с наибольшей условной вероятностью, чтобы сделать предсказание.

Вот пример использования условной вероятности для принятия решений в условиях неопределенности с целью предсказания для нейросетей на языке программирования Python с использованием библиотеки PyTorch:

ЛИСТИНГ 2.35. Пример использования условной вероятности для принятия решений в условиях неопределенности с целью предсказания

```
import torch
import torch.nn as nn
import torch.optim as optim
import numpy as np

# Создание нейронной сети
class NeuralNetwork(nn.Module):
    def __init__(self):
        super(NeuralNetwork, self).__init__()
        self.fc1 = nn.Linear(784, 128) # Полносвязный слой с 784
        # входами и 128 выходами
        self.fc2 = nn.Linear(128, 10) # Полносвязный слой с 128
        # входами и 10 выходами

    def forward(self, x):
        x = torch.flatten(x, 1) # Преобразование входного
        # изображения в одномерный тензор
        x = torch.relu(self.fc1(x)) # Применение ReLU к выходу
        # первого слоя
        x = self.fc2(x) # Выходной слой без функции активации
        # (после него будет применена softmax)
        return x

# Создание экземпляра модели
model = NeuralNetwork()

# Генерация случайных входных данных (например, изображений)
input_data = torch.randn(1, 784) # Генерация случайного
# изображения размером 28x28

# Прямой проход
outputs = model(input_data)

# Применение softmax для получения вероятностей классов
softmax = nn.Softmax(dim=1)
probs = softmax(outputs)

# Выбор класса с наибольшей условной вероятностью
predicted_class = torch.argmax(probs, dim=1).item()

# Вывод результата предсказания
print("Предсказанный класс:", predicted_class)
```

В этом примере мы создаем нейронную сеть, которая принимает в качестве входных данных одно изображение размером 28×28 . После прямого прохода мы получаем выходные вероятности для каждого класса с помощью функции **softmax**. Затем мы выбираем класс с наибольшей условной вероятностью как предсказанный класс.

2.2.8.5. Марковские модели

Вероятностные модели, такие как марковские цепи, используют условные вероятности для описания переходов между состояниями системы. Это позволяет моделировать последовательности событий и делать прогнозы о будущем на основе предыдущих состояний.

Вот пример использования Марковской модели условной вероятности для нейросетей на языке программирования Python с использованием библиотеки PyTorch:

ЛИСТИНГ 2.36. Пример использования Марковской модели условной вероятности

```
import torch
import torch.nn as nn
import torch.optim as optim
import numpy as np

# Создание нейронной сети
class MarkovModel(nn.Module):
    def __init__(self, input_size, hidden_size, output_size):
        super(MarkovModel, self).__init__()
        self.hidden_size = hidden_size
        self.hidden = nn.Linear(input_size + hidden_size, hidden_size)
        self.output = nn.Linear(hidden_size, output_size)
        self.softmax = nn.Softmax(dim=1)

    def forward(self, input, hidden):
```

```

        combined = torch.cat((input, hidden), 1)
        hidden = torch.tanh(self.hidden(combined))
        output = self.output(hidden)
        output_probs = self.softmax(output)
        return output_probs, hidden

    def init_hidden(self):
        return torch.zeros(1, self.hidden_size)

# Создание экземпляра модели
input_size = 10 # Размер входного вектора
hidden_size = 20 # Размер скрытого состояния
output_size = 5 # Размер выходного вектора
model = MarkovModel(input_size, hidden_size, output_size)

# Генерация случайных входных данных и начального скрытого состояния
input_data = torch.randn(1, input_size)
# Генерация случайного входного вектора
hidden_state = model.init_hidden() # Инициализация скрытого состояния

# Прямой проход
output_probs, next_hidden_state = model(input_data, hidden_state)

# Вывод результатов
print("Выходные вероятности:", output_probs)
print("Следующее скрытое состояние:", next_hidden_state)

```

В этом примере мы создаем Марковскую модель с одним скрытым слоем и применяем ее к случайным входным данным.

После прямого прохода мы получаем выходные вероятности для каждого класса с помощью функции **softmax**, а также следующее скрытое состояние модели.

Резюмируем информацию по разделу условной вероятности: условная вероятность является важным инструментом в машинном обучении, который позволяет моделировать зависимости между переменными, принимать решения на основе имеющейся информации и строить более адаптивные и точные вероятностные модели.

2.2.9. Цепное правило

Цепное правило, также известное как **правило умножения вероятностей**, применяется для вычисления вероятности совместного возникновения нескольких событий. Если события являются зависимыми, то вероятность совместного возникновения всех событий можно найти как произведение вероятностей каждого события при условии, что предыдущие события уже произошли.

Вот пример использования цепного правила в контексте машинного обучения для вычисления градиента функции ошибки по параметрам модели (например, нейронной сети) с использованием обратного распространения ошибки:

ЛИСТИНГ 2.37. Пример использования цепного правила в контексте машинного обучения для вычисления градиента функции ошибки по параметрам модели (например, нейронной сети) с использованием обратного распространения ошибки

```
import numpy as np

# Пример функции активации (сигмоид)
def sigmoid(x):
    return 1 / (1 + np.exp(-x))

# Пример производной функции активации
def sigmoid_derivative(x):
    return x * (1 - x)

# Пример реализации метода обратного распространения ошибки
def backpropagation(input_data, output_data, learning_rate, epochs):
    input_layer_size = input_data.shape[1]
    hidden_layer_size = 4
    output_layer_size = output_data.shape[1]

    # Инициализация весов сети
    weights_input_hidden = np.random.uniform(size=(input_layer_size,
hidden_layer_size))
    weights_hidden_output = np.random.uniform(size=(hidden_layer_
size, output_layer_size))
```

```

for epoch in range(epochs):
    # Прямое распространение
    hidden_layer_input = np.dot(input_data, weights_input_
hidden)
    hidden_layer_output = sigmoid(hidden_layer_input)
    output_layer_input = np.dot(hidden_layer_output, weights_
hidden_output)
    predicted_output = sigmoid(output_layer_input)

    # Вычисление ошибки
    output_error = output_data - predicted_output
    if epoch % 10000 == 0:
        print('Error:', np.mean(np.abs(output_error)))

    # Обратное распространение
    d_predicted_output = output_error * sigmoid_
derivative(predicted_output)
    output_layer_error = d_predicted_output.dot(weights_hidden_
output.T)
    d_hidden_layer_output = output_layer_error * sigmoid_
derivative(hidden_layer_output)

    # Обновление весов
    weights_hidden_output += hidden_layer_output.T.dot(d_
predicted_output) * learning_rate
    weights_input_hidden += input_data.T.dot(d_hidden_layer_
output) * learning_rate

    return weights_input_hidden, weights_hidden_output

# Пример использования метода обратного распространения ошибки
input_data = np.array([[0, 0],
                        [0, 1],
                        [1, 0],
                        [1, 1]])

output_data = np.array([[0],
                        [1],
                        [1],
                        [0]])

learning_rate = 0.1
epochs = 100000

weights_input_hidden, weights_hidden_output = backpropagation(input_
data, output_data, learning_rate, epochs)
print("Weights Input to Hidden:\n", weights_input_hidden)
print("Weights Hidden to Output:\n", weights_hidden_output)

```

В этом примере цепное правило используется для вычисления градиента функции ошибки по параметрам нейронной сети в обратном направлении через слои сети.

2.2.10. Независимость событий

Два события называются независимыми, если вероятность одного события не зависит от того, произошло ли другое событие.

Вот пример на языке Python с использованием библиотеки `scikit-learn` для демонстрации событий в контексте машинного обучения:

ЛИСТИНГ 2.38. Пример на языке Python с использованием библиотеки *scikit-learn* для демонстрации событий в контексте машинного обучения

```
from sklearn.datasets import load_iris
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import accuracy_score

# Загрузка данных
data = load_iris()
X = data.data
y = data.target

# Разделение данных на обучающий и тестовый наборы
X_train, X_test, y_train, y_test = train_test_split(X, y,
                                                    test_size=0.2, random_state=42)

# Обучение модели случайного леса
model = RandomForestClassifier(n_estimators=100, random_
                              state=42)
model.fit(X_train, y_train)

# Предсказание классов на тестовом наборе
y_pred = model.predict(X_test)

# Оценка точности модели
accuracy = accuracy_score(y_test, y_pred)
print("Точность модели:", accuracy)
```


Этот пример демонстрирует основные этапы в машинном обучении: загрузку данных, разделение на обучающий и тестовый наборы, обучение модели, предсказание и оценку точности.

2.2.11. Условная независимость событий

Вот пример на языке Python, демонстрирующий условную независимость событий при обучении модели на двух входных признаках:

ЛИСТИНГ 2.39. Пример на языке Python, демонстрирующий условную независимость событий при обучении модели на двух входных признаках

```
import numpy as np
from sklearn.linear_model import LogisticRegression

# Создание входных данных
X = np.array([[0, 0],
              [0, 1],
              [1, 0],
              [1, 1]])

# Создание целевых меток
y = np.array([0, 1, 1, 1])

# Логическая операция OR

# Обучение модели логистической регрессии
model = LogisticRegression()
model.fit(X, y)

# Предсказание на новых данных
new_data = np.array([[0, 0], # 0 OR 0 = 0
                     [0, 1], # 0 OR 1 = 1
                     [1, 0], # 1 OR 0 = 1
                     [1, 1]]) # 1 OR 1 = 1
predictions = model.predict(new_data)

print("Предсказания модели:", predictions)
```

В этом примере модель обучается предсказывать логическую операцию ИЛИ на основе двух входных признаков. Предсказания модели демонстрируют условную независимость событий: если один из признаков равен 1, то результат также равен 1, независимо от значения другого признака.

2.2.12. Математическое ожидание, дисперсия и ковариация

Математическое ожидание, дисперсия и ковариация — это ключевые характеристики случайных величин, которые широко используются в теории вероятностей и статистике, а также в машинном обучении.

2.2.12.1. Математическое ожидание

Математическое ожидание дискретной и непрерывных случайных величин и пример взаимодействия этих величин на языке Python:

ЛИСТИНГ 2.40. Пример взаимодействия дискретной и непрерывной случайных величин

```
import numpy as np

# Дискретная случайная величина
X_discrete = np.array([1, 2, 3, 4, 5]) # значения
P_discrete = np.array([0.1, 0.2, 0.3, 0.2, 0.2]) # вероятности

# Непрерывная случайная величина
X_continuous = np.linspace(0, 10, 1000) # значения
f_continuous = np.exp(-0.5 * (X_continuous - 5)**2) / np.sqrt(2 * np.pi)
# плотность

# Вычисление математических ожиданий
E_discrete = np.sum(X_discrete * P_discrete)
E_continuous = np.trapz(X_continuous * f_continuous, X_continuous)

print("Математическое ожидание дискретной случайной величины:",
      E_discrete)
print("Математическое ожидание непрерывной случайной величины:",
      E_continuous)
```

Этот пример демонстрирует вычисление математического ожидания для дискретной случайной величины (с использованием суммы) и для непрерывной случайной величины (с использованием интеграла), а также показывает, как они могут взаимодействовать в одной программе.

2.2.12.2. Дисперсия

Дисперсия случайной величины измеряет, насколько сильно значения случайной величины разбросаны относительно ее среднего значения.

Пример вычисления случайной величины на языке Python с использованием библиотеки NumPy:

ЛИСТИНГ 2.41. Пример расчета случайной величины

```
import numpy as np

# Пример случайной величины (например, оценки на экзамене)
scores = np.array([85, 90, 88, 92, 95])

# Вычисление дисперсии
variance = np.var(scores)

print("Дисперсия оценок на экзамене:", variance)
```

Этот код создает массив `scores`, представляющий оценки на экзамене. Затем он использует функцию `np.var()` из библиотеки NumPy для вычисления дисперсии этой случайной величины.

2.2.12.3. Ковариация

Ковариация между двумя случайными величинами измеряет, насколько они варьируются вместе.

Пример вычисления ковариации двух признаков на языке Python с использованием библиотеки NumPy:

ЛИСТИНГ 2.42. Пример ковариации двух признаков

```
import numpy as np

# Пример данных с двумя признаками (например, рост и вес)
heights = np.array([160, 165, 170, 175, 180]) # Рост в сантиметрах
weights = np.array([60, 65, 70, 75, 80])      # Вес в килограммах

# Вычисление ковариации
covariance = np.cov(heights, weights) [0, 1]

print("Ковариация между ростом и весом:", covariance)
```

Этот код создает два массива — **heights** и **weights**, представляющих данные о росте и весе. Затем он использует функцию `np.cov()` из библиотеки NumPy для вычисления ковариации между этими двумя признаками. Эти характеристики играют важную роль в анализе и моделировании случайных величин, а также в оценке и прогнозировании данных в контексте машинного обучения и статистики.

2.2.13. Часто встречающиеся распределения вероятности

В теории вероятностей и статистике существует множество распределений вероятности, каждое из которых имеет свои уникальные свойства и применения в различных областях.

Ниже представлены некоторые из наиболее часто встречающихся распределений вероятности.

2.2.13.1. Равномерное распределение

Все значения случайной величины имеют одинаковую вероятность.

Пример формулы равномерного распределения на языке Python:

ЛИСТИНГ 2.43. Пример формулы равномерного распределения

```
import numpy as np

# Генерация равномерно распределенных случайных чисел
# в диапазоне от 0 до 1
uniform_data = np.random.uniform(0, 1, 1000)
```

Этот код использует библиотеку NumPy для генерации 1000 случайных чисел, равномерно распределенных в диапазоне от 0 до 1.

2.2.13.2. Нормальное (Гауссовское) распределение

Симметричное вокруг среднего значения, с наибольшей плотностью вероятности вокруг среднего. Пример формулы нормального (Гауссовского) распределения на языке Python:

ЛИСТИНГ 2.44. Пример нормального (Гауссовского) распределения

```
import numpy as np
import matplotlib.pyplot as plt

# Генерация данных с нормальным распределением
mean = 0 # Среднее значение
std_dev = 1 # Стандартное отклонение
num_samples = 1000

# Генерация данных
normal_data = np.random.normal(mean, std_dev, num_samples)

# Визуализация данных
plt.hist(normal_data, bins=30, density=True, alpha=0.6, color='g')
plt.title('Нормальное (Гауссовское) распределение')
plt.xlabel('Значение')
plt.ylabel('Частота')
plt.show()
```

Этот код использует библиотеки NumPy и Matplotlib для генерации 1000 случайных чисел с нормальным распределением (среднее значение 0 и стандартное отклонение 1) и их визуализации в виде гистограммы.

2.2.13.3. Биномиальное распределение

Биномиальное распределение описывает количество успехов в серии независимых одинаково распределенных испытаний.

Пример формулы биномиального распределения на языке Python:

ЛИСТИНГ 2.45. Пример биномиального распределения

```
import numpy as np
import matplotlib.pyplot as plt

# Параметры биномиального распределения
n = 10 # количество испытаний
p = 0.5 # вероятность успеха

# Генерация данных с биномиальным распределением
binomial_data = np.random.binomial(n, p, 1000)

# Визуализация данных
plt.hist(binomial_data, bins=11, density=True, alpha=0.6, color='b')
plt.title('Биномиальное распределение')
plt.xlabel('Количество успехов в серии испытаний')
plt.ylabel('Частота')
plt.show()
```

Этот код использует библиотеки NumPy и Matplotlib для генерации 1000 случайных чисел с биномиальным распределением (10 испытаний с вероятностью успеха 0,5 каждое) и их визуализации в виде гистограммы.

2.2.13.4. Экспоненциальное распределение

Экспоненциальное распределение моделирует время между последовательными независимыми событиями, имеющими постоянную среднюю интенсивность. Так, например, может использоваться при моделировании времени между двумя событиями, такими как временные интервалы между проходом двух запросов к серверу.

Пример формулы экспоненциального распределения на языке Python:

ЛИСТИНГ 2.46. Пример экспоненциального распределения

```
import numpy as np
import matplotlib.pyplot as plt

# Параметр экспоненциального распределения (обратное значение
# среднего)
beta = 0.5

# Генерация данных с экспоненциальным распределением
exponential_data = np.random.exponential(scale=1/beta, size=1000)

# Визуализация данных
plt.hist(exponential_data, bins=30, density=True, alpha=0.6, color='r')
plt.title('Экспоненциальное распределение')
plt.xlabel('Значение')
plt.ylabel('Частота')
plt.show()
```

Этот код использует библиотеки NumPy и Matplotlib для генерации 1000 случайных чисел с экспоненциальным распределением с параметром $\beta = 0,5$ и их визуализации в виде гистограммы.

2.2.13.5. Геометрическое распределение

Геометрическое распределение описывает количество испытаний, требуемых для первого успеха в серии независимых испытаний Бернулли.

Пример формулы геометрического распределения на языке Python:

ЛИСТИНГ 2.47. Пример геометрического распределения

```
import numpy as np
import matplotlib.pyplot as plt

# Вероятность успеха (параметр геометрического распределения)
p = 0.3

# Генерация данных с геометрическим распределением
geometric_data = np.random.geometric(p, size=1000)

# Визуализация данных
plt.hist(geometric_data, bins=20, density=True, alpha=0.6, color='m')
plt.title('Геометрическое распределение')
plt.xlabel('Количество испытаний до первого успеха')
plt.ylabel('Частота')
plt.show()
```

Этот код использует библиотеки NumPy и Matplotlib для генерации 1000 случайных чисел с геометрическим распределением с вероятностью успеха $p = 0,3$ и их визуализации в виде гистограммы. Эти распределения широко используются в различных областях, таких как физика, экономика, биология и машинное обучение, для моделирования и анализа случайных явлений.

2.2.14. Употребляемые функции (или активационные функции)

Употребляемые функции (или активационные функции) играют ключевую роль в нейронных сетях и других моделях машинного обучения. Они добавляют нелинейность модели, позволяя ей учиться сложным зависимостям в данных.

Приведем некоторые из наиболее употребляемых функций и их полезные свойства.

2.2.14.1. Сигмоидная функция (Sigmoid)

Используется в задачах классификации. Пример формулы сигмоидной функции на языке Python:

ЛИСТИНГ 2.48. Пример сигмоидной функции

```
import numpy as np
import matplotlib.pyplot as plt

def sigmoid(x):
    return 1 / (1 + np.exp(-x))

# Генерация данных для построения графика
x_values = np.linspace(-10, 10, 100)
y_values = sigmoid(x_values)

# Визуализация сигмоидной функции
plt.plot(x_values, y_values, 'b-', label='Сигмоидная функция')
plt.title('Сигмоидная функция')
plt.xlabel('x')
plt.ylabel('sigmoid (x)')
plt.grid(True)
plt.legend()
plt.show()
```

Этот код использует библиотеки NumPy и Matplotlib для генерации значений сигмоидной функции для заданных значений x и их визуализации в виде графика.

2.2.14.2. Гиперболический тангенс (Tanh)

Пример формулы гиперболического тангенса на языке Python:

ЛИСТИНГ 2.49. Пример гиперболического тангенса

```
import numpy as np
import matplotlib.pyplot as plt

def tanh(x):
    return np.tanh(x)

# Генерация данных для построения графика
x_values = np.linspace(-10, 10, 100)
y_values = tanh(x_values)

# Визуализация гиперболического тангенса
plt.plot(x_values, y_values, 'r-', label='Гиперболический тангенс')
plt.title('Гиперболический тангенс')
plt.xlabel('x')
plt.ylabel('tanh(x)')
plt.grid(True)
plt.legend()
plt.show()
```

Этот код использует библиотеки NumPy и Matplotlib для генерации значений гиперболического тангенса для заданных значений x и их визуализации в виде графика.

Гиперболический тангенс широко используется в нейронных сетях и других алгоритмах машинного обучения для создания **нелинейных преобразований**.

2.2.14.3. ReLU (Rectified Linear Unit)

Пример функции ReLU (Rectified Linear Unit) на языке Python:

ЛИСТИНГ 2.50. Пример ReLU

```
import numpy as np

def relu(x):
    return np.maximum(0, x)

# Пример входных данных
x = np.array([-1, 2, 3, -4, 0, 5])

# Применение ReLU к входным данным
result = relu(x)

print("Результат после применения ReLU:", result)
```

Этот код применяет функцию ReLU (Rectified Linear Unit) к массиву входных данных x , заменяя все отрицательные значения нулем. Результат вычислений выводится на экран. Функция ReLU широко используется в нейронных сетях как активационная функция для добавления нелинейности.

2.2.14.4. Leaky ReLU

Пример функции Leaky ReLU на языке Python:

ЛИСТИНГ 2.51. Пример функции Leaky ReLU

```
import numpy as np

def leaky_relu(x, alpha=0.01):
    return np.where(x > 0, x, alpha * x)

Пример входных данных
x = np.array([-1, 2, 3, -4, 0, 5])

Применение Leaky ReLU к входным данным
result = leaky_relu(x)

print("Результат после применения Leaky ReLU:", result)
```

Этот код использует функцию Leaky ReLU к массиву входных данных x , заменяя отрицательные значения их произведением на коэффициент α (обычно выбирается небольшим положительным числом, например 0,01). Результат вычислений выводится на экран.

Функция Leaky ReLU является вариантом ReLU, который позволяет появиться небольшому наклону для отрицательных значений, чтобы избежать проблемы "мертвых" нейронов, которая может возникнуть при использовании обычной ReLU.

2.2.15. Непрерывные величины

Непрерывные величины — это переменные, которые могут принимать бесконечное количество значений в определенном интервале. В контексте статистики и вероятности непрерывные величины описываются с помощью плотности вероятности, которая указывает вероятность того, что случайная величина примет значение в определенном диапазоне.

Далее рассмотрим некоторые ключевые технические детали непрерывных величин.

2.2.15.1. Диапазон значений

Непрерывные величины могут принимать значения в любом интервале или на всей числовой прямой. Например, время, температура, скорость, вес и высота — все это примеры непрерывных величин.

Вот пример диапазона значений непрерывной величины в Python:

ЛИСТИНГ 2.52. Пример диапазона значений непрерывных величин

```
# Создаем диапазон значений от 0 до 10 с шагом 0.1
start = 0
end = 10
step = 0.1

# Генерируем диапазон значений
continuous_values = [value for value in range(start, end, step)]

# Выводим полученный диапазон значений
print(continuous_values)
```

Этот код создает диапазон значений непрерывной величины от 0 до 10 с шагом 0.1 и сохраняет его в списке *continuous_values*.

Затем он выводит этот диапазон значений.

2.2.15.2. Плотность вероятности

Для непрерывных величин вероятность конкретного значения *равна нулю* из-за бесконечного количества возможных значений. Вместо этого используется **плотность вероятности**, которая указывает вероятность того, что случайная величина примет значение в бесконечно малом интервале вокруг определенной точки.

Пример использования библиотеки Matplotlib для построения графика плотности вероятности непрерывных величин на языке Python:

ЛИСТИНГ 2.53. Пример плотности вероятности непрерывных величин

```
import numpy as np
import matplotlib.pyplot as plt
from scipy.stats import norm

# Генерируем выборку из нормального распределения
data = np.random.normal(loc=0, scale=1, size=1000)

# Строим гистограмму выборки
plt.hist(data, bins=30, density=True, alpha=0.5, color='b')

# Вычисляем среднее и стандартное отклонение выборки
mean = np.mean(data)
std_dev = np.std(data)

# Вычисляем плотность вероятности нормального распределения
# для данной выборки
xmin, xmax = plt.xlim()
x = np.linspace(xmin, xmax, 100)
p = norm.pdf(x, mean, std_dev)

# Строим график плотности вероятности нормального распределения
plt.plot(x, p, 'k', linewidth=2)
title = "Fit results: mean %.2f, std dev = %.2f" % (mean, std_dev)
plt.title(title)

plt.show()
```

Этот код генерирует выборку из нормального распределения, строит гистограмму выборки и на ее основе вычисляет и строит график плотности вероятности нормального распределения.

2.2.15.3. Функция распределения

Для непрерывных величин используется **функция распределения**, которая определяет вероятность того, что случайная величина примет значение меньше определенной точки или равное ей.

Пример использования библиотеки SciPy для вычисления и построения функции распределения непрерывных величин на языке Python:

ЛИСТИНГ 2.54. Пример функции распределения

```
import numpy as np
import matplotlib.pyplot as plt
from scipy.stats import norm

Определяем параметры нормального распределения
mu = 0
sigma = 1

Создаем массив значений x
x = np.linspace(-5, 5, 1000)

# Вычисляем функцию нормального распределения
cdf = norm.cdf(x, mu, sigma)

Строим график функции распределения
plt.plot(x, cdf, label='CDF')
plt.title('Cumulative Distribution Function (CDF) of Normal
Distribution')
plt.xlabel('x')
plt.ylabel('Cumulative Probability')
plt.legend()
plt.grid(True)
plt.show()
```

Этот пример определяет параметры нормального распределения, вычисляет его функцию распределения (CDF) с использованием библиотеки SciPy и строит график этой функции.

2.2.15.4. Ожидаемое значение и дисперсия

Для непрерывных величин также можно вычислить ожидаемое (среднее) значение и дисперсию, которые аналогичны их аналогам для дискретных величин, но используют интегралы вместо сумм.

Пример ожидаемого (среднего) значения и дисперсии непрерывных величин на языке Python с использованием библиотеки NumPy:

ЛИСТИНГ 2.55. Пример ожидаемого значения и дисперсии непрерывных величин

```
import numpy as np

# Пример нормально распределённой случайной величины
mean = 0
# Ожидаемое значение (среднее)
std_dev = 1
# Стандартное отклонение, корень из дисперсии
variance = std_dev ** 2
# Дисперсия
```

Для других распределений значения могут отличаться, но эти примеры показывают базовый подход.



ПРИМЕЧАНИЕ. Некоторые распределения вероятностей, описывающие непрерывные величины, включают нормальное распределение, экспоненциальное распределение, равномерное распределение и гамма-распределение. Понимание непрерывных величин и их особенностей важно для работы с данными, статистического анализа и построения моделей в машинном обучении.

2.2.16. Теория информации

Теория информации — это математическая теория, разработанная в середине XX века инженером и математиком Клодом Шенноном.

Она изучает передачу, хранение и обработку информации, а также измеряет количество информации в сообщениях.

Рассмотрим основные концепции теории информации.

2.2.16.1. Информационная энтропия

Информационная энтропия — это мера неопределенности в случайной переменной. Информационная энтропия выражает степень хаоса или неопределенности в системе.

Чем больше энтропия, тем менее предсказуема система. Формально информационная энтропия определяется как среднее значение количества информации, содержащейся в сообщении, и измеряется в битах.

Пример информационной энтропии для расчета энтропии в узле дерева решений на языке Python:

ЛИСТИНГ 2.56. Пример информационной энтропии для расчета энтропии в узле дерева решений

```
import numpy as np

def entropy(labels):
    _, counts = np.unique(labels, return_counts=True)
    probabilities = counts / len(labels)
    entropy = np.sum(probabilities * np.log2(probabilities))
    return entropy

# Пример меток классов
labels = [0, 1, 0, 1, 1]

# Рассчитываем информационную энтропию для данного набора меток классов
entropy_value = entropy(labels)
print("Information entropy:", entropy_value)
```

Этот пример рассчитывает информационную энтропию для заданного набора меток классов. В данном случае, если классы равномерно распределены,

то энтропия будет максимальной, а если все метки классов одинаковы, то энтропия будет минимальной.

2.2.16.2. Избыточность и избыточное кодирование

Избыточность и избыточное копирование — это избыточное количество информации, необходимое для передачи сообщения. Она возникает из-за ненужных или повторяющихся элементов в сообщении.

Избыточное кодирование позволяет уменьшить избыточность путем уменьшения количества бит, необходимых для передачи информации, с помощью эффективных методов кодирования, таких как код Хаффмана или арифметическое кодирование.

Пример избыточности. Предположим, у нас есть список чисел, и мы хотим найти сумму всех элементов списка.

ЛИСТИНГ 2.57. Пример избыточности

```
numbers = [1, 2, 3, 4, 5]

# Используем избыточное решение, применяя цикл
sum_of_numbers = 0
for num in numbers:
    sum_of_numbers += num
print("Сумма чисел:", sum_of_numbers)
```

В данном случае, хотя задача нахождения суммы элементов списка проста, мы использовали избыточный подход с использованием цикла, вместо того чтобы воспользоваться встроенной функцией `sum()`.

2.2.16.3. Пример избыточного копирования

Рассмотрим пример, где мы кодируем буквы алфавита в двоичные последовательности с помощью словаря.

ЛИСТИНГ 2.58. Пример избыточного кодирования

```
# Избыточное кодирование букв алфавита
encoding_dict = {
    'a': '000',
    'b': '001',
    'c': '010',
    'd': '011',
    'e': '100',
    # Повторение для каждой буквы алфавита
}

# Кодировем строку с помощью избыточного кодирования
text = "abcde"
encoded_text = ""
for char in text:
    encoded_text += encoding_dict[char]
print("Избыточно закодированный текст:", encoded_text)
```

Здесь каждая буква алфавита кодируется в трехбитную последовательность, что может считаться избыточным, особенно если использовать переменную длину кодирования для часто встречающихся символов.

2.2.17. Каналы связи и емкость канала

Каналы связи и емкость канала связи — это среда, через которую передается информация, например провод, радиоволны или оптическое волокно.

Емкость канала — это максимальное количество информации, которое может быть передано через канал за единицу времени. Она измеряется в битах в секунду (бит/с).

Пример канала связи

Предположим, у нас есть беспроводной канал связи между мобильным устройством и ближайшей базовой станцией. Этот канал используется для передачи данных, таких как текстовые сообщения, изображения, видео и т. д.

Емкость канала

Емкость канала определяется максимальной скоростью передачи данных через этот канал. Например, если максимальная скорость передачи данных по этому каналу составляет 10 мегабит в секунду (10 Mbps), то емкость этого канала составляет 10 мегабит в секунду.

Пример использования емкости канала

Предположим, что мы хотим передать видеофайл размером 100 мегабайт через этот канал. Мы можем использовать емкость канала для оценки времени, необходимого для передачи файла.

Если емкость канала составляет 10 мегабит в секунду, то, чтобы передать файл размером 100 мегабайт (800 мегабит), потребуется:

Время = Размер файла / Емкость канала = 800 мегабит / 10 мегабит в секунду = 80 секунд.

Таким образом, для передачи этого видеофайла через этот канал потребуется 80 секунд.

2.2.17.1. Шум и кодирование с коррекцией ошибок

Шум — это случайные искажения информации при передаче через канал связи.

Кодирование с коррекцией ошибок — это методы кодирования, которые позволяют исправлять ошибки, возникающие из-за шума в канале связи.

Пример шума

Предположим, что мы передаем цифровой сигнал через канал связи, но из-за воздействия внешних факторов, таких как электромагнитные помехи или плохое качество сигнала, часть информации искажается. Например, если мы передаем бит "0", шум может сделать его "1", и наоборот.

Пример кодирования с коррекцией ошибок

Одним из методов борьбы с шумом и ошибками в передаче данных является использование кодирования с коррекцией ошибок. Один из известных методов — это код Хэмминга.

ЛИСТИНГ 2.59. Пример кодирования с коррекцией ошибок (начало)**ЛИСТИНГ 2.60. Пример кодирования с коррекцией ошибок (продолжение)****ЛИСТИНГ 2.61. Пример кодирования с коррекцией ошибок (окончание)**

```
def calc_parity_bits(data_bits):
    # Определение количества битов четности
    m = len(data_bits)
    r = 1
    while 2 ** r - r - 1 < m:
        r += 1
    return r

def get_parity_positions(num_bits):
    positions = [2**i for i in range(num_bits)]
    return positions

def encode_hamming(data_bits):
    m = len(data_bits)
    r = calc_parity_bits(data_bits)
    n = m + r

    encoded = [None] * n
```

```

parity_positions = get_parity_positions(r)

# Заполняем биты данных
j = 0
for i in range(1, n + 1):
    if i in parity_positions:
        encoded[i - 1] = 0 # заполняем место под бит четности нулем
    else:
        encoded[i - 1] = int(data_bits[j])
        j += 1

# Вычисляем биты четности
for i in range(r):
    parity_pos = 2**i
    parity = 0
    for j in range(1, n + 1):
        if j & parity_pos == parity_pos:
            parity ^= encoded[j - 1]
    encoded[parity_pos - 1] = parity

return encoded

def introduce_error(encoded_bits, error_position):
    encoded_bits[error_position] ^= 1
    return encoded_bits

def decode_hamming(encoded_bits):
    n = len(encoded_bits)
    r = calc_parity_bits([0] * (n - calc_parity_bits(encoded_bits)))

    error_position = 0

    for i in range(r):
        parity_pos = 2**i
        parity = 0
        for j in range(1, n + 1):
            if j & parity_pos == parity_pos:
                parity ^= encoded_bits[j - 1]
        if parity:
            error_position += parity_pos

    if error_position:
        encoded_bits[error_position - 1] ^= 1

    decoded = []
    parity_positions = get_parity_positions(r)
    for i in range(1, n + 1):

```

```

        if i not in parity_positions:
            decoded.append(encoded_bits[i - 1])

    return decoded, error_position

# Пример использования
data_bits = "1011"
print(f"Original data: {data_bits}")

encoded_bits = encode_hamming(data_bits)
print(f"Encoded data: {''.join(map(str, encoded_bits))}")

# Внесение ошибки
error_position = 3 # например, ошибка на позиции 3
encoded_with_error = introduce_error(encoded_bits[:], error_position - 1)
print(f"Encoded data with error: {''.join(map(str, encoded_with_error))}")

decoded_bits, detected_error_position = decode_hamming(encoded_with_error)
print(f"Decoded data: {''.join(map(str, decoded_bits))}")
print(f"Detected error position: {detected_error_position}")

```

В этом примере мы демонстрируем передачу сообщения с использованием кодирования с коррекцией ошибок (код Хэмминга). После кодирования и декодирования сообщения мы можем обнаружить и исправить ошибки, возникающие из-за шума в канале связи.

В нейронных сетях **кодирование с коррекцией ошибок** часто используется для улучшения надежности передачи данных и повышения устойчивости моделей.

Вот несколько способов, как это может быть применено:

- **Dropout** — техника регуляризации, которая случайным образом обнуляет выходы нейронов во время обучения с определенной вероятностью. Это помогает предотвратить переобучение и улучшить обобщающую способность модели.

- **Аугментация данных** — при аугментации данных к исходным данным применяются случайные преобразования, такие как повороты, сдвиги, масштабирование и т.д. Это помогает создать больше разнообразных данных для обучения и делает модель устойчивее к различным вариантам входных данных.
- **Использование шума** — добавление случайного шума к входным данным или скрытым слоям может помочь модели обучаться более робастным и устойчивым способом.
- **Early stopping** — это метод, при котором обучение модели прекращается, когда ошибка на валидационном наборе данных начинает возрастать после определенного числа эпох. Это помогает избежать переобучения и сохранить обобщающую способность модели.
- **Batch normalization** — нормализует входные данные для каждого мини-батча во время обучения. Это помогает стабилизировать процесс обучения и ускоряет сходимость модели.

В целом эти методы помогают сделать нейронные сети более устойчивыми к шуму и изменениям в данных, что ведет к лучшим результатам обучения и обобщению на новых данных.

2.2.17.2. Информационная теорема

Одной из ключевых идей теории информации является **информационная теорема Шеннона**, которая утверждает, что существует теоретический предел для скорости передачи информации через канал связи, называемый емкостью канала. Этот предел зависит от ширины полосы пропускания канала и уровня шума.

Теория информации имеет широкое применение в различных областях, включая телекоммуникации, компьютерные сети, сжатие данных, криптографию, а также в машинном обучении и искусственном интеллекте.

Информационная теорема Шеннона может быть применена в контексте машинного обучения, особенно в задачах передачи данных и оценки эффективности алгоритмов обучения.

Вот пример ее использования.

- Предположим, у нас есть модель машинного обучения, которая должна классифицировать изображения на два класса: кошек и собак. Для обучения модели мы передаем большой набор изображений с соответствующими метками классов (кошка или собака).
- Информационная теорема Шеннона может быть использована для оценки эффективности передачи данных, например при передаче изображений через сеть. Она может помочь определить оптимальный объем данных, необходимых для обучения модели с определенной точностью и степенью уверенности.
- Кроме того, информационная теорема Шеннона может быть применена для оценки эффективности самой модели. Например, она может использоваться для оценки энтропии весов модели или для определения оптимального размера модели, минимизирующего избыточность и уменьшающего риск переобучения. Таким образом, информационная теорема Шеннона предоставляет важные инструменты для анализа и оптимизации процесса обучения и работы моделей машинного обучения.

2.2.18. Структурные и вероятностные модели

Структурные и вероятностные модели — это два основных подхода к моделированию систем и данных в области машинного обучения и статистики.

Рассмотрим их основные характеристики:

2.2.18.1. Структурные модели

В структурных моделях данные моделируются с использованием определенной структуры или графа, который отражает связи между различными переменными. Эти модели описывают, как различные компоненты системы взаимодействуют друг с другом, и часто используются для понимания причинно-следственных отношений.

Примеры структурных моделей включают байесовские сети, деревья решений, графовые модели и структурные уравнения. Структурные модели могут быть более интерпретируемыми и позволяют лучше понять внутренние зависимости в данных.

Таким образом, структурная модель в контексте нейронных сетей описывает архитектуру и связи между нейронами и слоями нейронной сети. Она определяет, как информация передается через сеть и какие преобразования выполняются на различных уровнях абстракции.

Приведем пример структурной модели нейронной сети.

Слой 1 (входной слой):

Входные нейроны: 784 (например, для задачи классификации рукописных цифр).

Функция активации: нет (данные просто проходят через этот слой).

Слой 2 (скрытый слой):

Нейроны: 256.

Функция активации: ReLU (Rectified Linear Unit).

Слой 3 (скрытый слой):

Нейроны: 128.

Функция активации: ReLU.

Слой 4 (выходной слой):

Нейроны: 10 (по количеству классов).

Функция активации: Softmax (для задачи классификации).

В этом примере структурной модели мы имеем нейронную сеть с четырьмя слоями: входным слоем, двумя скрытыми слоями и выходным слоем. Каждый слой содержит определенное количество нейронов и использует определенную функцию активации.

Такая структура модели может быть применена, например, для классификации изображений. Входной слой принимает пиксели изображения, а последующие слои выполняют постепенное преобразование данных до получения вероятностного распределения по классам на выходном слое с помощью функции активации Softmax. Эта структура модели является одной из множества возможных и может быть настроена и изменена в зависимости от конкретной задачи и требований.

2.2.18.2. Вероятностные модели

Вероятностные модели моделируют данные с использованием вероятностных распределений и статистических методов, чтобы определить вероятности различных событий или значений переменных.

Они могут быть использованы для прогнозирования, классификации, кластеризации и генерации данных. Примеры вероятностных моделей включают нормальное распределение, биномиальное распределение, модель скрытых марков и гауссовские смеси. Вероятностные модели часто используются для работы с неопределенностью и шумом в данных.

Например, скрытые марковские модели (НММ) и гауссовские смеси (GMM) могут использоваться в таких задачах, как генерация текста, распознавание речи, генерация изображений и многое другое.

Приведем примеры их применения.

Скрытые марковские модели (НММ)

НММ — это статистическая модель, которая представляет собой вероятностную модель, состоящую из наблюдаемых и скрытых переменных, связанных между собой с помощью вероятностных переходов.

В контексте нейронных сетей НММ могут быть использованы для моделирования последовательностей данных, таких как временные ряды, текст или речь.

Пример использования НММ в нейронных сетях может быть в задаче распознавания речи. Нейронная сеть может использоваться для извлечения признаков из аудиофайла, а затем скрытая марковская модель может использоваться для моделирования временных зависимостей между фонемами или словами в речевой последовательности.

Гауссовские смеси (GMM)

GMM — это статистическая модель, которая представляет собой смесь нескольких гауссовских распределений. Она часто используется для моделирования распределения данных, особенно когда данные имеют сложную структуру или состоят из смеси различных групп.

В контексте нейронных сетей GMM могут использоваться в таких задачах, как генерация изображений или распознавание объектов на изображениях. Пример использования GMM в нейронных сетях может быть в задаче генерации изображений. Нейронная сеть может генерировать скрытые признаки изображения, которые затем могут быть моделированы с помощью GMM для генерации новых изображений с похожими характеристиками.

2.2.18.3. Совместное использование

В некоторых случаях структурные и вероятностные модели могут быть скомбинированы для создания более мощных и гибких моделей. Например, байесовские сети объединяют в себе структурную организацию графа и вероятностные распределения, чтобы представить зависимости между переменными и их вероятностные свойства.

Одним из способов комбинирования структурных и вероятностных моделей в нейронных сетях является использование **генеративно-сопоставительных сетей (GAN)**, которые представляют собой комбинацию двух нейронных сетей: генератора и дискриминатора.

Вот пример такого комбинирования.

- **Генератор** (структурная модель): генератор принимает на вход случайный шумовой вектор и генерирует изображение. Обычно это сверточная нейронная сеть, которая постепенно увеличивает размерность и сложность данных, пока не сгенерирует изображение.
- **Дискриминатор** (вероятностная модель): дискриминатор принимает на вход изображение и выдает вероятность того, что оно реальное (настоящее) или сгенерированное генератором (фальшивое). Дискриминатор представляет собой бинарный классификатор, который оценивает реалистичность изображения.
- **Процесс обучения GAN** заключается в том, чтобы обучать генератор создавать все более реалистичные изображения, которые дискриминатор не может отличить от реальных изображений. Таким образом, генератор и дискриминатор конкурируют между собой, приводя сеть к равновесию, при котором генерируемые изображения становятся практически неотличимыми от реальных.

Это мощный пример комбинации структурной и вероятностной моделей в нейронных сетях, который позволяет создавать реалистичные данные, такие как изображения, звуки или тексты.

Выбор между структурными и вероятностными моделями зависит от конкретной задачи, доступных данных и требований к модели. Каждый из этих подходов имеет свои сильные стороны и применим в различных ситуациях.

2.3. Дифференциальное и интегральное исчисление для оптимизации функций и определения производных, градиентного спуска

2.3.1. Дифференциальное исчисление

Дифференциальное исчисление — это раздел математики, который изучает, как меняются функции при изменении их входных значений. Например, если у нас есть функция, описывающая скорость автомобиля в зависимости от времени, дифференциальное исчисление помогает нам понять, как быстро меняется скорость в определенный момент времени.

Дифференциальное исчисление играет ключевую роль в обучении нейронных сетей через **метод обратного распространения ошибки**.

Вот простой пример использования дифференциального исчисления в контексте нейросетей.

Допустим, у нас есть нейронная сеть с одним входом, одним скрытым слоем с одним нейроном и одним выходом. Пусть функция активации этого нейрона — сигмоида, а функция потерь — квадратичная. Мы хотим обучить эту нейронную сеть на примерах входных данных и соответствующих им

целевых значений. Обучение сводится к минимизации функции потерь относительно параметров нейронной сети.

Процесс обучения включает в себя несколько шагов:

- **Прямое распространение (forward propagation):** для каждого входного примера вычисляем выход нейронной сети, применяя текущие параметры (веса и смещения) и функции активации.
- **Вычисление функции потерь:** для каждого примера вычисляем значение функции потерь, сравнивая выход нейронной сети с соответствующим целевым значением.
- **Обратное распространение (backward propagation):** используя градиент функции потерь по параметрам нейронной сети, вычисляем градиенты, показывающие, как изменение каждого параметра влияет на функцию потерь.
- **Обновление параметров:** используя градиенты, обновляем параметры нейронной сети с использованием метода градиентного спуска или его вариантов.

Дифференциальное исчисление важно здесь для вычисления градиентов, которые указывают направление наибольшего убывания функции потерь. Это позволяет эффективно обновлять параметры нейронной сети для минимизации потерь и повышения качества предсказаний модели.

2.3.2. Интегральное исчисление

Интегральное исчисление — это другой раздел математики, который изучает площади и объемы под графиками функций. Например, если у нас есть функция, описывающая скорость автомобиля в течение определенного периода времени, интегральное исчисление позволяет нам вычислить общее расстояние, пройденное автомобилем за этот период времени.

Интегральное исчисление в контексте нейросетей реже используется непосредственно, чем дифференциальное исчисление. Однако его можно применять, например, для анализа структуры нейронной сети или для определения оптимальных гиперпараметров.

Приведем пример, как интегральное исчисление может быть использовано.

Оптимизация гиперпараметров с использованием интегрального исчисления: предположим, что у нас есть нейронная сеть с несколькими гиперпараметрами, такими как количество слоев, количество нейронов в каждом слое, скорость обучения и другие. Мы хотим оптимизировать эти гиперпараметры для повышения производительности или улучшения обобщения модели.

Одним из подходов к оптимизации гиперпараметров является использование **интегрального исчисления** для анализа производительности модели по всему пространству гиперпараметров. Например, мы можем определить функцию, которая оценивает качество модели в зависимости от набора гиперпараметров.

Далее, мы можем использовать интегральные методы, такие как **методы численного интегрирования**, для оценки поведения функции производительности модели в пространстве гиперпараметров. Например, мы можем вычислить интеграл квадрата функции производительности по всем значениям гиперпараметров.

Это позволяет нам оценить общую производительность модели для различных наборов гиперпараметров и определить оптимальные значения гиперпараметров, которые максимизируют качество модели.

Хотя прямое применение интегрального исчисления в обучении нейронных сетей не так распространено, оно может быть использовано в контексте оптимизации гиперпараметров для повышения производительности и эффективности нейронных сетей.

2.3.3. Оптимизация функций

Оптимизация функций — это процесс нахождения минимума или максимума функции.

Например, если у нас есть функция, описывающая затраты производства в зависимости от количества произведенных единиц товара, оптимизация помогает нам найти количество единиц товара, при котором затраты будут минимальными.

Оптимизация функций в контексте нейросетей играет ключевую роль при обучении моделей, так как ее целью является нахождение оптимальных параметров модели для минимизации функции потерь.

Вот примеры методов оптимизации функций, которые широко используются в нейронных сетях:

- **Градиентный спуск (Gradient Descent)** — это один из наиболее распространенных методов оптимизации. Он использует градиент функции потерь по параметрам модели для обновления параметров в направлении наибольшего убывания функции потерь. Варианты градиентного спуска включают стохастический градиентный спуск (SGD), мини-пакетный градиентный спуск и метод адаптивного градиентного спуска, такой как Adam.
- **Метод Ньютона (Newton's Method)** — это метод оптимизации, который использует информацию о вторых производных функции потерь для нахождения оптимальных параметров модели. Он может сходиться быстрее, чем градиентный спуск, но требует больше вычислительных ресурсов.
- **Метод Бroyдена-Флетчера-Гольдфарба-Шанно (BFGS)** — это квазиньютоновский метод оптимизации, который использует приближенные оценки гессиана функции потерь для обновления параметров модели.
- **Метод оптимизации с использованием градиентов структуры (Gradient-based Structural Optimization)** — этот метод используется для оптимизации архитектуры нейронных сетей, таких как количество слоев, количество нейронов и функции активации, путем прямой оптимизации градиентов структурной функции потерь.
- **Метод оптимизации гиперпараметров (Hyperparameter Optimization)** — это метод оптимизации, который настраивает гиперпараметры модели, такие как скорость обучения, количество эпох обучения и размер мини-пакета, для улучшения производительности модели.

Это лишь несколько примеров методов оптимизации функций в контексте нейронных сетей. Каждый из них имеет свои преимущества и недостатки и может быть эффективным в зависимости от конкретной задачи и структуры модели.

2.3.4. Производные

Производные — это показатели, которые показывают, насколько быстро меняется значение функции в определенной точке.

Они помогают определить наклон кривой функции в этой точке. Например, если у нас есть функция, описывающая высоту водопада в зависимости от расстояния, производная помогает нам понять, насколько быстро высота меняется на определенном расстоянии.

Производная функции в контексте нейронных сетей является ключевым инструментом для оптимизации параметров модели при обучении. Она показывает, как изменение параметров модели влияет на значение функции потерь или другой целевой метрики. Рассмотрим пример производной функции потерь по параметру веса в одном из слоев нейронной сети.

Предположим, у нас есть нейронная сеть с одним скрытым слоем, состоящим из трех нейронов. Пусть L будет функцией потерь нашей нейронной сети, которую мы хотим минимизировать. Пусть также w_{ij} будет весом связи между i -м входом и j -м нейроном в скрытом слое.

Тогда производная функции потерь L по параметру w_{ij} показывает, как изменение веса влияет на изменение функции потерь. Формально это записывается как:

$$\frac{\partial L}{\partial w_{ij}}$$

Эта производная используется в алгоритме обратного распространения ошибки для обновления весов нейронной сети. Она позволяет определить направление и скорость изменения весов, которые приведут к минимизации функции потерь.

Пример использования производной на Python:

ЛИСТИНГ 2.62. Пример вычисления производной функции потерь

```
# Пример вычисления производной функции потерь по параметру веса в
нейронной сети

# Гипотетическая функция потерь
def loss_function(y_true, y_pred):
    return (y_true - y_pred) ** 2

# Пример вычисления производной функции потерь по параметру веса
def compute_weight_gradient(input_value, true_output, predicted_output,
weight):
    # Вычисляем градиент функции потерь по параметру веса
    loss_gradient = 2 * (true_output - predicted_output) * input_value

    return loss_gradient

# Пример использования производной для обновления веса в нейронной сети
learning_rate = 0.01
true_output = 1
predicted_output = 0.8
weight = 0.5
input_value = 0.6

# Вычисляем градиент функции потерь по параметру веса
gradient = compute_weight_gradient(input_value, true_output,
predicted_output, weight)

# Обновляем вес с использованием градиента и скорости обучения
updated_weight = weight - learning_rate * gradient

print("Updated weight:", updated_weight)
```

Это пример использования производной функции потерь по параметру веса в нейронной сети для обновления весов при обучении.

2.3.5. Градиентный спуск

Градиентный спуск — это метод оптимизации, который используется для нахождения минимума функции. Он основан на использовании производных и шаговом обновлении параметров функции в направлении, в котором функция убывает быстрее всего.

Например, если у нас есть функция, которую мы хотим минимизировать (например, функция потерь в машинном обучении), градиентный спуск позволяет нам находить оптимальные значения параметров для минимизации этой функции.

Пример уравнения градиентного спуска для оптимизации функций на языке Python в задаче машинного обучения для нахождения оптимальных значений параметров и минимизации функции потерь.

ЛИСТИНГ 2.63. Пример уравнения градиентного спуска (начало)

ЛИСТИНГ 2.64. Пример уравнения градиентного спуска (окончание)

```
import numpy as np

def f(x):
    """Целевая функция, которую мы хотим минимизировать."""
    return (x - 3) ** 2

def df(x):
    """Производная целевой функции."""
    return 2 * (x - 3)

def gradient_descent(learning_rate, num_iterations):
    """Градиентный спуск для нахождения минимума функции f."""
    # Начальное приближение
    x = np.random.randn()
    history = [x] # Для хранения значений x на каждой итерации

    for i in range(num_iterations):
        gradient = df(x)
        x -= learning_rate * gradient
        history.append(x)
        print(f"Iteration {i+1}: x = {x}, f(x) = {f(x)}")

    return x, history

# Параметры градиентного спуска
learning_rate = 0.1
num_iterations = 100
```

```

optimal_x, history = gradient_descent(learning_rate, num_
iterations)
print(f"Optimal x: {optimal_x}")
print(f"Minimum value of f(x): {f(optimal_x)}")

# Визуализация процесса
import matplotlib.pyplot as plt

x_values = np.linspace(-2, 8, 400)
y_values = f(x_values)

plt.plot(x_values, y_values, label='f(x) = (x-3)^2')
plt.scatter(history, [f(x) for x in history], color='red', s=10,
label='Gradient Descent Steps')
plt.xlabel('x')
plt.ylabel('f(x)')
plt.legend()
plt.title('Gradient Descent Optimization')
plt.show()

```

Объяснение кода

Определение целевой функции и её производной:

- $f(x)$: функция, которую мы хотим минимизировать.
- $df(x)$: её производная.

Функция `gradient_descent`:

- Принимает параметры `learning_rate` (скорость обучения) и `num_`
`iterations` (число итераций).
- Начинает с случайного начального значения x .
- На каждой итерации обновляет значение x по правилу градиентного спуска:

```
x -= learning_rate * gradient
```

- Сохраняет историю значений x для последующей визуализации.

Параметры градиентного спуска:

- `learning_rate`: определяет размер шага в направлении антиградиента.

- `num_iterations`: количество итераций, которые будет выполнен градиентный спуск.

Визуализация:

- Построение графика целевой функции и шагов градиентного спуска.

2.4. Теория графов

Теория графов — это область математики, изучающая связи между объектами, в которой объекты представлены как вершины, а их связи — как ребра.

2.4.1. Графы

Графы — это совокупность вершин и ребер, которые соединяют их. Вершины могут представлять объекты или сущности, а ребра — связи или отношения между ними.

Теория графов часто применяется в контексте нейросетей для моделирования и анализа их структуры. Например, нейронные сети могут быть представлены в виде графов, где узлы представляют собой нейроны, а ребра — связи между ними.

Это позволяет анализировать свойства сети, такие как эффективность обучения, влияние узлов на общую структуру сети и т. д. Также теория графов может применяться для оптимизации архитектуры нейронных сетей, например для определения наиболее эффективных путей обучения или оптимизации вычислительных ресурсов.

Один из примеров применения теории графов — это анализ структуры сверточных нейронных сетей (CNN). В CNN узлы представляют слои сети, а ребра — направленные связи между слоями. Используя теорию графов,

исследователи могут анализировать структуру сети для определения оптимальных путей распространения информации, выявления узких мест или оптимизации вычислительных ресурсов. Также можно применять методы графов для анализа зависимостей между различными слоями и настройки параметров сети для улучшения ее производительности.

Вот простой пример использования теории графов на языке программирования Python с помощью библиотеки NetworkX для создания и визуализации графа:

ЛИСТИНГ 2.65. Пример использования теории графов на языке программирования Python с помощью библиотеки NetworkX для создания и визуализации графа

```
import networkx as nx
import matplotlib.pyplot as plt

# Создание графа
G = nx.Graph()

# Добавление вершин
G.add_nodes_from([1, 2, 3, 4, 5])

# Добавление рёбер
G.add_edges_from([(1, 2), (1, 3), (2, 3), (3, 4), (4, 5)])

# Визуализация графа
nx.draw(G, with_labels=True, node_color='lightblue', node_size=1000,
font_size=12, font_weight='bold')
plt.title("Пример графа")
plt.show()

import tensorflow as tf

# Гиперпараметры
learning_rate = 0.01
epochs = 100
batch_size = 32

# Загрузка данных
mnist = tf.keras.datasets.mnist
(x_train, y_train), _ = mnist.load_data()
x_train, y_train = x_train / 255.0, tf.keras.utils.to_categorical(y_train, 10)
```

```
# Создание модели
model = tf.keras.models.Sequential([
    tf.keras.layers.Flatten(input_shape=(28, 28)),
    tf.keras.layers.Dense(128, activation='relu'),
    tf.keras.layers.Dense(10, activation='softmax')
])

# Компиляция модели с оптимизатором градиентного спуска SGD
optimizer = tf.keras.optimizers.SGD(learning_rate=learning_rate)
model.compile(optimizer=optimizer,
              loss='categorical_crossentropy',
              metrics=['accuracy'])

# Обучение модели с использованием градиентного спуска
for epoch in range(epochs):
    for batch in range(len(x_train) // batch_size):
        start = batch * batch_size
        end = start + batch_size
        x_batch, y_batch = x_train[start:end], y_train[start:end]

        with tf.GradientTape() as tape:
            predictions = model(x_batch)
            loss = tf.keras.losses.categorical_crossentropy(y_batch,
                                                            predictions)
            loss = tf.reduce_mean(loss)

            gradients = tape.gradient(loss, model.trainable_variables)
            optimizer.apply_gradients(zip(gradients, model.trainable_variables))

        print(f'Epoch {epoch + 1}, Loss: {loss.numpy()}')

print("Training finished!")
```

Этот код создает простой ненаправленный граф с пятью вершинами и пятью ребрами и визуализирует его с помощью библиотеки NetworkX.

2.4.2. Деревья решений

Дерево решений — это тип графа, который используется в задачах классификации и регрессии в машинном обучении. Он состоит из узлов (вершин), которые представляют собой

признаки данных, и ребер, которые представляют возможные решения (например, "да" или "нет"). Каждый узел решения делает выбор на основе значений признаков, чтобы предсказать целевую переменную.

Вот пример уравнения на языке Python, демонстрирующий тип графа дерева решений в контексте машинного обучения с использованием библиотеки `scikit-learn`:

ЛИСТИНГ 2.66. Пример уравнения загрузки набора данных *Iris*

```
from sklearn.datasets import load_iris
from sklearn.tree import DecisionTreeClassifier, export_text

# Загрузка датасета Iris
iris = load_iris()
X = iris.data
y = iris.target

# Создание и обучение модели дерева решений
clf = DecisionTreeClassifier()
clf = clf.fit(X, y)

# Вывод структуры дерева решений в виде текста
tree_rules = export_text(clf, feature_names=iris.feature_names)
print(tree_rules)
```

Этот код загружает набор данных *Iris*, создает и обучает модель дерева решений для классификации видов "ирисов" на основе их характеристик.

Затем он выводит структуру дерева решений в виде текста, показывая, какие признаки используются для разделения данных на каждом узле и какие решения принимаются в листовых узлах.

Приведем еще примеры их применения.

2.4.2.1. Классификация

Представим задачу классификации, в которой необходимо определить, пройдет ли заявка на кредит. В этом случае дерево решений может быть построено на основе различных признаков заявителя, таких как его возраст, доход, кредитная история и т. д. Каждый узел в дереве представляет собой проверку значения одного из признаков, а каждое ребро соответствует возможному значению этого признака. Целевая переменная (пройдет заявка или нет) определяется в листовых узлах дерева.

2.4.2.2. Регрессия

Рассмотрим задачу предсказания цены недвижимости. Дерево решений может быть построено на основе различных характеристик домов, таких как площадь, количество комнат, район и т. д. Каждый узел в дереве может представлять собой проверку значения одной из характеристик, а каждое ребро — возможное значение этой характеристики. В листовых узлах дерева содержится предсказанная цена дома.

Таким образом, деревья решений представляют собой графическую модель, которая помогает принимать решения на основе входных данных, разделяя пространство признаков на различные регионы и определяя значение целевой переменной в каждом из них.

2.4.3. Нейронные сети

Нейронные сети — это еще один тип графа, используемый в машинном обучении, который моделирует работу человеческого мозга. Он состоит из нейронов (вершин), соединенных между собой весами (ребрами).

Каждый нейрон принимает входные данные, умножает их на веса и передает результат через функцию активации другим нейронам. Это позволяет нейронной сети извлекать сложные закономерности из данных и делать прогнозы или принимать решения.

Вот пример типа графов нейронной сети на языке Python с использованием библиотеки TensorFlow:

ЛИСТИНГ 2.67. Пример типа графов нейронные сети

```
import tensorflow as tf

# Создание последовательной модели нейронной сети
model = tf.keras.Sequential([
    tf.keras.layers.Dense(64, activation='relu', input_shape=(784,)),
    tf.keras.layers.Dense(64, activation='relu'),
    tf.keras.layers.Dense(10, activation='softmax')
])

# Компиляция модели
model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])

# Обучение модели на датасете MNIST
mnist = tf.keras.datasets.mnist
(x_train, y_train), (x_test, y_test) = mnist.load_data()
x_train, x_test = x_train / 255.0, x_test / 255.0
model.fit(x_train, y_train, epochs=5)

# Оценка точности модели на тестовом наборе данных
model.evaluate(x_test, y_test)
```

Этот код создает простую нейронную сеть с двумя скрытыми слоями и одним выходным слоем.

- Входной слой имеет 784 узла (плоское представление изображения размером 28×28 пикселей).
- Скрытые слои имеют по 64 нейрона с функцией активации ReLU, а выходной слой состоит из 10 нейронов с функцией активации Softmax для классификации на 10 классов (цифры от 0 до 9).
- Модель компилируется с оптимизатором Adam и функцией потерь **sparse_categorical_crossentropy**. Затем модель обучается на датасете MNIST, содержащем рукописные цифры, и оценивается на тестовом наборе данных для оценки ее точности.

Таким образом, графы помогают нам визуализировать и понять структуры данных, такие как деревья решений и нейронные сети, и использовать их для решения различных задач в машинном обучении.

2.5. Оптимизация для нахождения решений задач, таких как минимизация функции потерь в машинном обучении

Оптимизация в контексте машинного обучения — это процесс нахождения наилучших параметров модели, которые минимизируют ошибку или функцию потерь на тренировочных данных.

Давайте представим, что у нас есть модель машинного обучения, которая, например, пытается предсказать цены на недвижимость на основе различных характеристик домов, таких как площадь, количество комнат и расстояние до центра города. Мы обучаем эту модель на некоторых данных и хотим, чтобы она предсказывала цены как можно точнее.

Для этого нам нужно оптимизировать параметры модели таким образом, чтобы ошибка между предсказанными и реальными ценами была минимальной. Мы используем функцию потерь, которая измеряет, насколько наша модель ошибается в предсказаниях.

Процесс оптимизации заключается в том, чтобы изменять параметры модели таким образом, чтобы минимизировать эту функцию потерь. Для этого часто используются методы оптимизации, такие как градиентный спуск, которые итеративно обновляют параметры модели в направлении, в котором функция потерь уменьшается.

Итак, оптимизация в машинном обучении — это процесс настройки параметров модели таким образом, чтобы минимизировать ошибку на тренировочных данных и получить более точные предсказания на новых данных.

Вот несколько примеров уравнений, используемых для оптимизации в машинном обучении.

2.5.1. Градиентный спуск

Градиентный спуск — это один из наиболее распространенных методов оптимизации, который используется для минимизации функции потерь.

Шаг градиентного спуска — это основной компонент алгоритма обучения нейронных сетей.

Вот пример шага градиентного спуска на языке Python, с использованием библиотеки TensorFlow:

ЛИСТИНГ 2.68. Пример шага градиентного спуска (начало)

```
import tensorflow as tf

# Гиперпараметры
learning_rate = 0.01
epochs = 100
batch_size = 32

# Загрузка данных
mnist = tf.keras.datasets.mnist
(x_train, y_train), _ = mnist.load_data()
x_train, y_train = x_train / 255.0, tf.keras.utils.to_categorical(y_train, 10)

# Создание модели
model = tf.keras.models.Sequential([
    tf.keras.layers.Flatten(input_shape=(28, 28)),
    tf.keras.layers.Dense(128, activation='relu'),
    tf.keras.layers.Dense(10, activation='softmax')
])

# Компиляция модели с оптимизатором градиентного спуска SGD
optimizer = tf.keras.optimizers.SGD(learning_rate=learning_rate)
model.compile(optimizer=optimizer,
              loss='categorical_crossentropy',
              metrics=['accuracy'])
```

ЛИСТИНГ 2.69. Пример шага градиентного спуска (окончание)

```
# Обучение модели с использованием градиентного спуска
for epoch in range(epochs):
    for batch in range(len(x_train) // batch_size):
        start = batch * batch_size
        end = start + batch_size
        x_batch, y_batch = x_train [start: end], y_train[start:end]

        with tf.GradientTape() as tape:
            predictions = model(x_batch)
            loss = tf.keras.losses.categorical_crossentropy(y_batch,
predictions)
            loss = tf.reduce_mean (loss)

            gradients = tape.gradient(loss, model.trainable_variables)
            optimizer.apply_gradients(zip(gradients, model.trainable_
variables))

        print (f' Epoch {epoch + 1}, Loss: {loss.numpy()}')

print("Training finished!")
```

В этом примере выполняется градиентный спуск для обучения нейронной сети на данных MNIST. На каждой итерации обучения вычисляются предсказания модели и функция потерь для мини-пакета данных (batch), затем вычисляются градиенты функции потерь по параметрам модели с использованием автоматического дифференцирования TensorFlow.

Градиенты затем используются для обновления параметров модели в направлении уменьшения потерь с помощью выбранного оптимизатора (в данном случае стохастический градиентный спуск — SGD). В конце каждой эпохи выводится значение функции потерь.

2.5.2. Метод наименьших квадратов (МНК)

Метод наименьших квадратов используется для решения задач регрессии.

Вот пример уравнения на языке Python, демонстрирующий использование метода наименьших квадратов (МНК) для решения задачи линейной регрессии:

ЛИСТИНГ 2.70. Пример уравнения метода наименьших квадратов

```
import numpy as np

# Исходные данные
X = np.array([[1, 1], [1, 2], [2, 2], [2, 3]])
y = np.dot (X, np.array([1, 2])) + 3

# Применение МНК для решения задачи линейной регрессии
coefficients = np.linalg.lstsq(X, y, rcond=None)[0]

print("Коэффициенты регрессии:", coefficients)
```

В этом примере переменная X представляет собой матрицу признаков, где каждая строка представляет один образец данных, а переменная y содержит значения целевой переменной для соответствующих образцов данных.

Мы используем функцию `np.linalg.lstsq()` из библиотеки NumPy для решения уравнения метода наименьших квадратов. Результатом является массив коэффициентов регрессии, которые минимизируют сумму квадратов разностей между предсказанными значениями и истинными значениями целевой переменной.

2.5.3. Логистическая регрессия

В логистической регрессии функция потерь определяется как кросс-энтропия.

Вот пример реализации логистической регрессии на языке Python с использованием библиотеки `scikit-learn`:

ЛИСТИНГ 2.71. Пример логистической регрессии

```

import numpy as np
from sklearn.datasets import load_iris
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score

# Загрузка датасета Iris
iris = load_iris()
X = iris.data
y = iris.target

# Разделение данных на обучающий и тестовый наборы
X_train, X_test, y_train, y_test = train_test_split(X, y, test_
size=0.2, random_state=42)

# Создание и обучение модели логистической регрессии
model = LogisticRegression()
model.fit(X_train, y_train)

# Предсказание на тестовом наборе данных
y_pred = model.predict(X_test)

# Оценка точности модели
accuracy = accuracy_score(y_test, y_pred)
print("Точность модели логистической регрессии на тестовом наборе
данных: {:.2f}".format(accuracy))

```

В этом примере мы используем датасет Iris для задачи классификации.

- Мы разделяем данные на обучающий и тестовый наборы с помощью функции `train_test_split()`.
- Затем мы создаем и обучаем модель логистической регрессии с помощью класса `LogisticRegression` из библиотеки `scikit-learn`.
- После обучения модели мы делаем предсказания на тестовом наборе данных и оцениваем точность модели с помощью метрики `accuracy_score`.

Эти уравнения используются для оптимизации параметров модели в машинном обучении с целью минимизации функции потерь и улучшения качества прогнозов.

2.6. Настоящее и перспективы математических основ машинного обучения

Математические основы машинного обучения играют решающую роль в развитии этой области. Существует много математических методов и теорий, которые используются для разработки алгоритмов машинного обучения, а также для понимания их работы и эффективного применения.

В настоящее время математические методы, такие как линейная алгебра, вероятность, статистика, оптимизация и теория графов, лежат в основе многих алгоритмов машинного обучения. Они позволяют моделировать и анализировать данные, выявлять закономерности, обучать модели на основе имеющихся данных и делать прогнозы на новых данных.

Перспективы математических основ машинного обучения весьма обширны. С развитием математических методов и технологий, а также с появлением новых идей и исследований мы можем ожидать появления более мощных и эффективных алгоритмов машинного обучения. Например, развитие теории глубокого обучения и улучшение методов оптимизации позволят создавать более сложные и точные модели, способные работать с большими объемами данных и решать сложные задачи.

Таким образом, **математические основы машинного обучения** остаются ключевым компонентом его развития и прогресса и будут продолжать играть важную роль в будущем.

Да, искусственный интеллект (ИИ) сейчас претерпел значительные изменения и стал неотъемлемой частью нашей повседневной жизни. Он активно применяется во многих сферах, таких как медицина, финансы, транспорт, образование и другие.

Генерация изображений с помощью искусственного интеллекта — это одна из захватывающих и популярных областей.

Технологии генеративных моделей, таких как генеративно-состязательные сети (GAN) и автоэнкодеры, позволяют создавать реалистичные и убедительные изображения на основе обучающих данных.

Применение ИИ в генерации изображений привело к созданию удивительных результатов в различных областях, таких как искусство, дизайн, киноиндустрия, игровая индустрия и многое другое. Это открывает новые возможности для творчества и вдохновляет на новые идеи и проекты.

Это один из прекрасных примеров того, как искусственный интеллект может стать мощным инструментом для творчества и вдохновения, расширяя границы нашего воображения и открывая новые горизонты в различных областях жизни.

2.7. Типы нейросетей и их использование

2.7.1. Многослойные перцептроны




Рис. 2.72. Архитектурный граф многослойного перцептрона с двумя скрытыми слоями




Рис. 2.73. Направление двух основных потоков для многослойного перцептрона

Многослойный перцептрон (MLP) — это классическая архитектура искусственной нейронной сети, которая состоит из нескольких слоев нейронов, включая входной слой, скрытые слои и выходной слой.

В каждом слое нейроны связаны с нейронами предыдущего и последующего слоев. Является одним из наиболее распространенных типов нейронных сетей и широко используется в различных задачах машинного обучения, таких как классификация, регрессия и прогнозирование.

MLP был предложен в 1960-х годах, однако его развитие и популярность значительно возросли в конце 1980-х и начале 1990-х годов, когда стали доступны более мощные компьютеры и улучшились алгоритмы обучения.

В течение последних десятилетий MLP продолжает развиваться благодаря улучшениям в алгоритмах оптимизации, появлению новых функций активации, регуляризации и других методов обучения. Также разработаны различные вариации архитектуры MLP, включая глубокие MLP с большим числом скрытых слоев, сверточные нейронные сети, рекуррентные нейронные сети

и другие. Эти различные вариации расширяют применимость MLP для различных задач машинного обучения и искусственного интеллекта.

Вот пример уравнения на языке Python с применением многослойного перцептрона с одним скрытым слоем и сигмоидной функцией:

ЛИСТИНГ 2.74. Пример применения многослойного перцептрона с одним скрытым слоем и сигмоидной функцией

```
import numpy as np

# Входные данные
input_data = np.array([0.1, 0.2, 0.3])

# Веса для скрытого слоя
hidden_weights = np.array([[0.4, 0.5, 0.6],
                             [0.7, 0.8, 0.9]])

# Веса для выходного слоя
output_weights = np.array([0.5, 0.6])

# Пересчёт значений скрытого слоя
hidden_layer_values = np.dot(input_data, hidden_weights.T)

# Применение функции активации (например, сигмоиды)
hidden_activation = 1 / (1 + np.exp(-hidden_layer_values))

# Пересчёт значений выходного слоя
output = np.dot(hidden_activation, output_weights)

print("Результат:", output)
```

Этот код демонстрирует применение многослойного перцептрона с одним скрытым слоем и сигмоидной функцией активации для перевода входных данных в выходные.

Вот основные характеристики **многослойного перцептрона**:

- **Структура:** MLP состоит из нескольких слоев нейронов, включая входной, скрытые и выходной слои. Каждый нейрон в одном слое связан с каждым нейроном в следующем слое.

Входные данные подаются на входной слой, а выходные значения получаются на выходном слое.

- **Активация:** в каждом нейроне MLP применяется функция активации, которая определяет его выход на основе взвешенной суммы входных значений. Распространенными функциями активации являются сигмоида, гиперболический тангенс ($\tanh$) и ReLU (Rectified Linear Unit).
- **Обучение:** обучение MLP происходит путем настройки весов и смещений в нейронах с помощью алгоритма обратного распространения ошибки. Этот процесс включает в себя передачу информации от выходного слоя к входному, чтобы вычислить ошибку прогноза, а затем обновление параметров сети, чтобы минимизировать эту ошибку.
- **Использование:** MLP используется для решения широкого спектра задач, включая классификацию, регрессию, аппроксимацию функций и многое другое. Он может быть применен к данным с различными типами и размерностями, что делает его универсальным инструментом для анализа и прогнозирования.

2.7.2. Глубокие многослойные перцептроны

Вариантом **MLP** являются глубокие нейронные сети, состоящие из большого числа скрытых слоев. Они способны обнаруживать сложные закономерности в данных и достигать высокой точности в решении задач машинного обучения. **MLP** остается одним из наиболее популярных и эффективных методов в машинном обучении благодаря своей простоте, гибкости и способности к решению разнообразных задач.

Вот пример уравнения на языке Python для глубокого многослойного перцептрона:

ЛИСТИНГ 2.75. Пример применения глубокого многослойного перцептрона с двумя скрытыми слоями и сигмоидной функцией

```
import numpy as np

# Входные данные
input_data = np.array([0.1, 0.2, 0.3])

# Веса для скрытых слоев
hidden_weights1 = np.array([[0.1, 0.2, 0.3],
                             [0.4, 0.5, 0.6]])
hidden_weights2 = np.array([[0.2, 0.3],
                             [0.5, 0.6]])

# Веса для выходного слоя
output_weights = np.array([0.4, 0.7])

# Пересчёт значений скрытых слоев
hidden_layer1_values = np.dot(input_data, hidden_weights1.T)
hidden_activation1 = 1 / (1 + np.exp(-hidden_layer1_values))

hidden_layer2_values = np.dot(hidden_activation1, hidden_weights2.T)
hidden_activation2 = 1 / (1 + np.exp(-hidden_layer2_values))

# Пересчёт значений выходного слоя
output = np.dot(hidden_activation2, output_weights)

print("Результат:", output)
```

Этот код демонстрирует глубокий многослойный перцептрон с двумя скрытыми слоями и сигмоидной функцией активации для перевода входных данных в выходные.

2.7.3. Сверточные нейронные сети (CNN)

Сверточные нейронные сети (CNN) — это тип нейронных сетей, который эффективно обрабатывает данные с пространственной структурой, такие как изображения.

Они широко используются в области компьютерного зрения для таких задач, как классификация изображений, распознавание объектов, сегментация и многое другое.




Рис. 2.76. Сеть свертки для обработки изображений, например для распознавания рукописного текста

Сверточные сети способны специализировать нейронные сети для обработки данных с четко выраженной сеточной топологией и масштабировать подобные модели к задачам очень большого размера.

Вот пример определения сверточной нейронной сети с двумя сверточными слоями, пулингом и двумя полносвязными слоями на языке программирования Python с использованием библиотеки TensorFlow:

ЛИСТИНГ 2.77. Пример определения сверточной нейронной сети с двумя сверточными слоями, пулингом и двумя полносвязными слоями на языке программирования Python с использованием библиотеки *TensorFlow*

```
import tensorflow as tf

# Определение модели
model = tf.keras.models.Sequential([
    # Сверточный слой 1
    tf.keras.layers.Conv2D(32, (3, 3), activation='relu', input_shape=(28, 28, 1)),
```

```
# Пулинг слой 1
tf.keras.layers.MaxPooling2D((2, 2)),
# Сверточный слой 2
tf.keras.layers.Conv2D(64, (3, 3), activation='relu'),
# Пулинг слой 2
tf.keras.layers.MaxPooling2D((2, 2)),
# Преобразование многомерного вектора в одномерный
tf.keras.layers.Flatten(),
# Полносвязный слой 1
tf.keras.layers.Dense(128, activation='relu'),
# Полносвязный слой 2
tf.keras.layers.Dense(10, activation='softmax') # 10 классов
для классификации
])

# Компиляция модели
model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
# Вывод структуры модели
model.summary()
```

Этот код создает модель сверточной нейронной сети с двумя сверточными слоями с функцией активации ReLU, пулингом после каждого сверточного слоя и двумя полносвязными слоями. Количество фильтров и размеры сверточных ядер заданы произвольно.

Вот основные характеристики CNN:

- **Сверточные слои:** основной компонент CNN — это сверточные слои, которые применяют фильтры (ядра свертки) к входным данным, чтобы извлечь признаки изображения. Эти фильтры перемещаются по изображению, выполняя операцию свертки, что позволяет обнаруживать различные характеристики, такие как грани, текстуры и формы.
- **Пулинг-слои:** после сверточных слоев обычно следуют слои пулинга, которые уменьшают размер признакового пространства, сохраняя при этом ключевую информацию. Это помогает улучшить вычислительную эффективность сети и уменьшить количество параметров для обучения.
- **Полносвязные слои:** в конце CNN обычно добавляют полносвязные слои, которые принимают выходные данные из предыдущих слоев и ис-

пользуют их для классификации или регрессии. Эти слои объединяют признаки, выученные предыдущими слоями, для принятия окончательного решения.

- **Обучение и передача обучения:** CNN обучаются с использованием обратного распространения ошибки, аналогично другим типам нейронных сетей. Однако они имеют большое количество параметров, что может потребовать значительного объема данных для обучения. Для задач с ограниченным объемом данных часто используется передача обучения, когда предварительно обученные модели CNN адаптируются к новым задачам.
- **Применение:** CNN успешно применяются во многих областях компьютерного зрения, включая распознавание лиц, автомобилей, животных, классификацию изображений медицинских снимков и многое другое. Они обладают способностью к извлечению высокоуровневых признаков из изображений и способны работать с большими объемами данных.

2.7.4. Рекуррентные нейронные сети

Рекуррентные нейронные сети (RNN) — это тип нейронных сетей, которые обрабатывают последовательные данные с переменной длиной ввода. Они обладают способностью запоминать предыдущие состояния и использовать их для обработки текущего входа.

RNN широко применяются в задачах, где важен контекст и последовательность данных, таких как анализ текста, генерация текста, прогнозирование временных рядов и многое другое.

Также их можно применять к **двумерным пространственным данным** (изображениям), а если речь идет о данных, в которых участвует время, то в сети могут быть связи, ведущие назад во времени, но при условии, что последовательность определена до передачи ее сети.




Рис. 2.78. Рекуррентная сеть без выходов. Эта сеть просто обрабатывает информацию из входа x , включая ее в состояние h , которое передается дальше во времени.

Слева: принципиальная схема. Черный квадратик обозначает задержку на один временной шаг. Справа: та же сеть в виде развернутого графа вычислений, в котором каждая вершина ассоциирована с одним моментом времени

Вот пример уравнения на языке Python для рекуррентной нейронной сети с использованием библиотеки PyTorch:

ЛИСТИНГ 2.79. Пример уравнения на языке Python для рекуррентной нейронной сети с использованием библиотеки PyTorch

```
import torch
import torch.nn as nn

# Определение архитектуры рекуррентной нейронной сети
class RNN(nn.Module):
    def __init__(self, input_size, hidden_size, num_layers, output_size):
        super(RNN, self).__init__()
        self.hidden_size = hidden_size
        self.num_layers = num_layers
        self.rnn = nn.RNN(input_size, hidden_size, num_layers, batch_first=True)
        self.fc = nn.Linear(hidden_size, output_size)

    def forward(self, x):
        # Инициализация скрытого состояния
        h0 = torch.zeros(self.num_layers, x.size(0), self.hidden_size).to(x.device)

        # Проход по рекуррентным слоям
        out, _ = self.rnn(x, h0)
```

```

# Применение линейного слоя к выходу последнего временного шага
out = self.fc(out[:, -1, :])
return out

# Создание экземпляра модели
input_size = 10
hidden_size = 20
num_layers = 2
output_size = 5
model = RNN(input_size, hidden_size, num_layers, output_size)

# Пример использования модели для предсказания
# Предположим, у нас есть тензор input_data размером (batch_size, seq_
length, input_size)
# Где batch_size - количество образцов в пакете, seq_length - длина
последовательности, input_size - размерность входных данных
input_data = torch.randn(3, 5, 10)
# Пример входных данных (3 образца, каждый с 5 временными шагами и 10
признаками)
output = model(input_data)

print("Результат предсказания:", output)

```

Вот основные характеристики RNN:

- **Рекуррентность:** основное отличие RNN от других типов нейронных сетей — это возможность передавать информацию от предыдущего временного шага к текущему. Это позволяет им моделировать последовательные данные, сохраняя контекст и зависимости между данными.
- **Скрытые состояния:** RNN содержат скрытые состояния, которые представляют собой внутреннее представление текущего состояния сети. Эти скрытые состояния обновляются на каждом временном шаге, учитывая текущий вход и предыдущее скрытое состояние.
- **Долгосрочная зависимость:** в обычных RNN возникает проблема исчезающего градиента, когда информация о предыдущих временных шагах теряется из-за ограниченной способности модели обрабатывать долгосрочные зависимости. Для решения этой проблемы были разработаны различные варианты RNN, такие как LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Unit), которые обладают способностью эффективнее сохранять информацию на длительные временные интервалы.

- **Обучение:** обучение RNN происходит с использованием алгоритма обратного распространения ошибки, аналогично другим типам нейронных сетей. Однако в RNN также учитывается последовательность данных при обновлении параметров модели.
- **Применение:** RNN широко применяются в задачах, где важна последовательность данных, таких как анализ текста, машинный перевод, генерация текста, прогнозирование временных рядов, обработка речи и многое другое. Они успешно используются в различных областях, таких как естественный язык, финансы, медицина и другие.

2.7.5. Генеративно-сопоставительные сети (GAN)

Генеративно-сопоставительные сети (GAN) — это тип нейронных сетей, введенный в 2014 году Яном Гудфеллоу и его коллегами. Они представляют собой модель, состоящую из двух основных компонентов: генератора и дискриминатора, которые соревнуются друг с другом в процессе обучения.

GAN широко используются для генерации новых данных, таких как изображения, звуки, тексты и т.д., которые могут быть использованы в различных приложениях — искусстве, дизайне, развлечениях, медицине и многом другом.

Наиболее известна генеративно-сопоставительная модель, работающая с изображениями, — **StyleGAN**.

Она активно развивается и имеет большое количество расширений (например, существуют разнообразные методы ее обращения).




Рис. 2.80. Слева: традиционный генератор. Справа: генератор модели StyleGAN¹

Вот пример уравнения на языке Python для генеративно-состязательной сети (GAN) с использованием библиотеки PyTorch:

ЛИСТИНГ 2.81. Пример реализации генеративно-состязательной сети (GAN) с использованием библиотеки PyTorch для обучения на наборе данных MNIST

```
import torch
import torch.nn as nn
import torch.optim as optim
import torchvision
import torchvision.transforms as transforms
from torch.utils.data import DataLoader
from torchvision.datasets import MNIST

# Определение генератора
class Generator(nn.Module):
    def __init__(self, latent_dim, image_shape):
```

¹ Источник: <https://arxiv.org/pdf/1812.04948.pdf>

```

super(Generator, self).__init__()
self.latent_dim = latent_dim
self.image_shape = image_shape

self.model = nn.Sequential(
    nn.Linear(latent_dim, 128),
    nn.LeakyReLU(0.2, inplace=True),
    nn.Linear(128, 256),
    nn.BatchNorm1d(256),
    nn.LeakyReLU(0.2, inplace=True),
    nn.Linear(256, 512),
    nn.BatchNorm1d(512),
    nn.LeakyReLU(0.2, inplace=True),
    nn.Linear(512, 1024),
    nn.BatchNorm1d(1024),
    nn.LeakyReLU(0.2, inplace=True),
    nn.Linear(1024, image_shape),
    nn.Tanh()
)

def forward(self, z):
    img = self.model(z)
    img = img.view(img.size(0), *self.image_shape)
    return img

# Определение дискриминатора
class Discriminator(nn.Module):
    def __init__(self, image_shape):
        super(Discriminator, self).__init__()
        self.image_shape = image_shape

    self.model = nn.Sequential(
        nn.Linear(image_shape, 512),
        nn.LeakyReLU(0.2, inplace=True),
        nn.Linear(512, 256),
        nn.LeakyReLU(0.2, inplace=True),
        nn.Linear(256, 1),
        nn.Sigmoid()
    )

    def forward(self, img):
        img_flat = img.view(img.size(0), -1)
        validity = self.model(img_flat)
        return validity

# Параметры
latent_dim = 100
image_shape = (28, 28)

```

```

lr = 0.0002
batch_size = 64
epochs = 10

# Инициализация генератора и дискриминатора
generator = Generator(latent_dim, image_shape)
discriminator = Discriminator(image_shape)

# Оптимизаторы
optimizer_G = optim.Adam(generator.parameters(), lr=lr)
optimizer_D = optim.Adam(discriminator.parameters(), lr=lr)
adversarial_loss = nn.BCELoss()

# Обучение GAN
for epoch in range(epochs):
    for i, (imgs, _) in enumerate(data_loader):

        # Генерация шума
        z = torch.randn(batch_size, latent_dim)

        # Генерация изображений
        gen_imgs = generator(z)

        # Обучение дискриминатора
        real_loss = adversarial_loss(discriminator(imgs), torch.
ones(batch_size, 1))
        fake_loss = adversarial_loss(discriminator(gen_imgs.detach()),
torch.zeros(batch_size, 1))
        d_loss = (real_loss + fake_loss) / 2

        optimizer_D.zero_grad()
        d_loss.backward()
        optimizer_D.step()

        # Обучение генератора
        gen_loss = adversarial_loss(discriminator(gen_imgs), torch.
ones(batch_size, 1))

        optimizer_G.zero_grad()
        gen_loss.backward()
        optimizer_G.step()

        if i % 100 == 0:
            print(
                f"[Epoch {epoch}/{epochs}] [Batch {i}/{len(data_
loader)}] [D loss: {d_loss.item()}] [G loss: {gen_loss.item()}]"
            )

```

Этот код демонстрирует пример реализации генеративно-состязательной сети (GAN) с использованием библиотеки PyTorch для обучения на наборе данных MNIST.

Вот основные характеристики GAN:

- **Генератор:** генератор в GAN принимает на вход случайный шум или вектор и пытается сгенерировать новые данные, которые максимально похожи на обучающие данные. Обычно генератор представлен как нейронная сеть, которая преобразует входной шум в выходные данные.
- **Дискриминатор:** дискриминатор в GAN принимает на вход данные и пытается отличить реальные данные от сгенерированных генератором. Он также представлен как нейронная сеть, которая классифицирует входные данные как реальные или сгенерированные.
- **Обучение:** обучение GAN происходит через альтернативную минимизацию функции потерь генератора и дискриминатора. Генератор стремится минимизировать вероятность дискриминатора классифицировать его выходные данные как сгенерированные, тогда как дискриминатор стремится максимизировать эту вероятность.
- **Создание новых данных:** после обучения GAN генератор может быть использован для генерации новых данных, которые могут быть очень реалистичными и похожими на обучающие данные. Это позволяет создавать новые изображения, звуки, тексты и другие элементы, которые могут быть использованы в различных приложениях.
- **Применение:** GAN широко используются в различных областях, включая генерацию изображений, анимации, музыки, текста, видео и многое другое. Они позволяют создавать новые и уникальные данные, которые могут быть использованы в искусстве, дизайне, развлечениях, а также для улучшения реальности в различных приложениях.

2.7.6. Инструменты и библиотеки для работы с нейросетями

Когда речь идет о работе с нейронными сетями, обычно используются несколько популярных инструментов, языков программирования, библиотек и фреймворков. Рассмотрим их подробнее.

2.7.6.1. Языки программирования

Python является одним из наиболее распространенных и удобных языков программирования для работы с нейронными сетями благодаря его простоте, гибкости и богатой системе библиотек.

Выделим основные преимущества Python:

- **Простота использования:** Python имеет простой и понятный синтаксис, что делает его идеальным выбором для начинающих и опытных разработчиков. Это позволяет легко понять и использовать различные библиотеки глубокого обучения.
- **Большое сообщество:** Python обладает огромным сообществом разработчиков, включая множество специалистов по машинному обучению и глубокому обучению. Это означает, что всегда можно найти полезные ресурсы, библиотеки и решения проблем.
- **Богатые библиотеки:** Python имеет множество библиотек для глубокого обучения, таких как TensorFlow, PyTorch, Keras и другие. Эти библиотеки предоставляют различные функции и инструменты для разработки, обучения и тестирования нейронных сетей.
- **Гибкость:** Python — это язык с открытым исходным кодом, который предлагает множество возможностей для настройки и расширения. Это позволяет разработчикам создавать и адаптировать алгоритмы и модели глубокого обучения под свои потребности.

В целом Python является идеальным выбором для работы с нейронными сетями благодаря своей простоте, богатым библиотекам и поддержке широкого сообщества разработчиков.

MATLAB также часто используется для прототипирования и исследований в области нейронных сетей благодаря своим инструментам для математического моделирования и анализа данных.

Рассмотрим основные преимущества и некоторые недостатки языка программирования MATLAB:

- **Мощный инструмент для численных вычислений:** MATLAB предоставляет обширный набор функций и инструментов для численных вычислений, линейной алгебры, статистики, обработки сигналов, изображений и многого другого. Это делает его идеальным инструментом для инженеров, ученых и исследователей, работающих в области науки и техники.
- **Простота использования:** MATLAB имеет простой и интуитивно понятный синтаксис, что делает его легким для изучения и использования. Большинство операций можно выполнить с помощью нескольких строк кода, что ускоряет процесс разработки и отладки.
- **Интеграция с графическим интерфейсом:** MATLAB обладает мощным графическим интерфейсом, который позволяет визуализировать данные, строить графики, анимации и интерактивные приложения. Это делает MATLAB полезным инструментом для анализа данных и визуализации результатов.
- **Богатая экосистема:** MATLAB имеет обширную экосистему, включая дополнительные пакеты и инструменты, такие как Simulink для моделирования и симуляции динамических систем, и множество библиотек и функций, созданных сообществом MATLAB.
- **Лицензионная модель:** одним из недостатков MATLAB является его лицензионная модель, которая может быть дорогой для отдельных пользователей или небольших организаций. Однако существуют альтернативы с открытым исходным кодом, такие как Octave, которые предоставляют схожий функционал бесплатно.

В целом MATLAB — мощный инструмент для численных вычислений с простым синтаксисом, богатым набором функций и удобным графическим интерфейсом, который делает его широко используемым в научных и инженерных приложениях. Однако его лицензионная модель может быть ограничивающим фактором для некоторых пользователей.

2.7.6.2. Библиотеки и фреймворки

Разработанный компанией Google, **TensorFlow** является одним из самых популярных и мощных фреймворков для глубокого обучения, который обладает широкими возможностями для создания и обучения различных типов нейронных сетей.

Особенности **TensorFlow**:

- **Мощный инструмент для глубокого обучения:** TensorFlow является одной из самых популярных и мощных библиотек для глубокого обучения. Она предоставляет широкий набор инструментов и функций для создания, обучения и развертывания различных типов нейронных сетей.
- **Гибкость и масштабируемость:** TensorFlow обладает высокой степенью гибкости и масштабируемости, позволяя разработчикам создавать различные типы моделей, включая сверточные нейронные сети, рекуррентные нейронные сети, генеративно-состязательные сети и многое другое. Она также поддерживает распределенное обучение на нескольких устройствах, что позволяет эффективно использовать большие объемы данных и вычислительные ресурсы.
- **Широкая поддержка и активное сообщество:** TensorFlow имеет большое и активное сообщество разработчиков, которое предоставляет множество ресурсов, библиотек и решений для различных задач машинного обучения и глубокого обучения — документацию, учебные материалы, примеры кода, различные расширения и пакеты.

- **Интеграция с другими инструментами:** TensorFlow интегрируется с другими популярными инструментами и библиотеками для работы с данными, такими как TensorFlow Extended (TFX), TensorFlow Data Validation (TFDV), TensorFlow Probability (TFP) и многими другими. Это делает TensorFlow полезным инструментом для разработки полноценных решений в области машинного обучения и искусственного интеллекта.

В целом TensorFlow — это мощный инструмент для разработки и развертывания нейронных сетей, который обладает широкими возможностями, высокой гибкостью и активным сообществом разработчиков.

Разработанный Facebook, **PyTorch** предоставляет гибкие инструменты для работы с нейронными сетями и глубоким обучением, а также удобную работу с динамическими графами вычислений.

Особенности PyTorch:

- **Интуитивно понятный интерфейс:** PyTorch обладает простым и интуитивно понятным интерфейсом, что делает его идеальным для начинающих и опытных разработчиков. Его динамический вычислительный граф позволяет пользователям определять и изменять граф вычислений на лету, что облегчает отладку и экспериментирование.
- **Гибкость и удобство:** PyTorch предоставляет широкий набор инструментов для создания и обучения различных типов нейронных сетей, включая сверточные нейронные сети, рекуррентные нейронные сети, трансформеры и многое другое. Он также поддерживает различные устройства, включая CPU, GPU и даже TPU, что делает его мощным инструментом для разработки высокопроизводительных моделей машинного обучения.
- **Обширное сообщество и документация:** PyTorch имеет активное сообщество разработчиков, которое предоставляет множество ресурсов, библиотек и учебных материалов для обучения и разработки. Он также имеет хорошо структурированную документацию и множество примеров кода, что облегчает изучение и использование библиотеки.

- **Интеграция с другими инструментами:** PyTorch интегрируется с другими популярными инструментами и библиотеками для работы с данными, такими как TorchVision для компьютерного зрения, TorchText для обработки естественного языка и многими другими. Это делает PyTorch полезным инструментом для разработки полноценных решений в области машинного обучения и искусственного интеллекта.

В целом PyTorch — это мощный и гибкий инструмент для разработки и развертывания нейронных сетей, который обладает простым интерфейсом, богатыми возможностями и активным сообществом разработчиков.

Keras является высокоуровневым API для работы с нейронными сетями, который позволяет быстро создавать и обучать модели, основываясь на фреймворках TensorFlow, Theano и CNTK.

Основные преимущества **Keras**:

- **Простота использования:** Keras известен своим простым и интуитивно понятным интерфейсом, который делает его идеальным выбором для начинающих и быстрым способом создания прототипов моделей глубокого обучения. Он предоставляет простой API, который позволяет пользователям легко создавать, обучать и оценивать нейронные сети.
- **Универсальность:** Keras обладает широкой поддержкой различных фреймворков глубокого обучения, включая TensorFlow, Microsoft Cognitive Toolkit (CNTK) и Theano. Это делает Keras универсальным инструментом для разработки моделей глубокого обучения независимо от выбранного фреймворка.
- **Богатый набор функций:** Keras предоставляет обширный набор функций и инструментов для создания различных типов нейронных сетей, включая сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN), генеративно-сопоставительные сети (GAN) и многие другие. Он также имеет богатую библиотеку предварительно обученных моделей, которые можно использовать в качестве основы для собственных проектов.

- **Интеграция с TensorFlow:** начиная с версии 2.0 Keras стал частью библиотеки TensorFlow, что обеспечивает еще более глубокую интеграцию и лучшую производительность при использовании этих инструментов вместе. Это также облегчает использование продвинутых функций TensorFlow в Keras.
- **Обучающие материалы и поддержка:** как и TensorFlow, Keras имеет обширное сообщество разработчиков и предоставляет множество обучающих материалов, документации и примеров кода, что облегчает изучение и использование этой библиотеки.

В целом Keras — это мощный и простой в использовании инструмент для разработки моделей глубокого обучения, который обладает широкой поддержкой и богатым набором функций.

Caffe предоставляет быстрый и эффективный фреймворк для разработки глубоких нейронных сетей, особенно подходящий для задач классификации изображений и обработки видео.

Немного о **Caffe**:

- **Эффективность обучения и инференса:** Caffe изначально разрабатывался для эффективного выполнения операций обучения и инференса нейронных сетей на графических процессорах (GPU). Это делает его привлекательным выбором для задач, требующих высокой производительности.
- **Простота в использовании:** Caffe имеет простой и интуитивно понятный конфигурационный файл (prototxt), который позволяет определить архитектуру модели и параметры обучения. Это делает его привлекательным для быстрого прототипирования и экспериментирования.
- **Поддержка различных архитектур:** Caffe предоставляет возможность создания различных типов нейронных сетей, включая сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN) и генеративно-сопоставительные сети (GAN). Он также имеет богатую библиотеку предварительно обученных моделей.

- **Ограниченная поддержка и активность сообщества:** в последние годы активность сообщества вокруг Caffe снизилась, особенно после выхода новых библиотек, таких как TensorFlow и PyTorch, которые предоставляют более широкие возможности и лучшую поддержку. Это может означать, что поиск решений и поддержка в случае проблем могут быть ограниченными.
- **Требует знаний C++:** хотя Caffe предоставляет простой интерфейс для определения модели, для расширения функциональности или решения сложных задач может потребоваться знание языка программирования C++, так как ядро Caffe реализовано на этом языке.

В целом Caffe является мощным и эффективным инструментом для обучения и использования нейронных сетей, особенно в областях, где требуется высокая производительность. Однако из-за снижения активности сообщества могут возникнуть ограничения в поддержке и развитии этой библиотеки.

2.7.6.3. Инструменты для визуализации и обработки данных

Matplotlib является популярной библиотекой для создания графиков и визуализации данных в Python, что делает его полезным инструментом для анализа результатов и визуализации архитектур нейронных сетей.

Немного о библиотеке **Matplotlib**:

- **Гибкость и функциональность:** Matplotlib предоставляет широкий спектр инструментов для создания различных типов графиков и визуализации данных. Она поддерживает создание статических, интерактивных и анимационных графиков, что делает ее универсальным инструментом для визуализации данных.
- **Простота в использовании:** Matplotlib обладает простым и интуитивно понятным интерфейсом, что позволяет пользователям легко создавать графики с помощью нескольких строк кода. Ее API построено на принципах, аналогичных тем, что используются в MATLAB, что делает ее знакомой для многих пользователей.

- **Обширная документация и сообщество:** Matplotlib имеет обширную документацию и множество примеров кода, что облегчает изучение и использование этой библиотеки. Она также имеет большое сообщество пользователей и разработчиков, которые предоставляют поддержку и разделяют свои знания и опыт.
- **Интеграция с другими библиотеками:** Matplotlib интегрируется с другими популярными библиотеками для анализа данных, такими как NumPy, Pandas и SciPy, что делает ее идеальным инструментом для визуализации результатов анализа данных.
- **Постоянное развитие:** Matplotlib постоянно развивается и обновляется, добавляя новые функции и улучшения, что делает ее актуальной и конкурентоспособной в сравнении с другими инструментами визуализации данных.

В целом Matplotlib является одной из лучших библиотек для визуализации данных в Python благодаря своей гибкости, простоте использования и богатому набору функций.

Pandas предоставляет мощные инструменты для обработки и анализа данных в Python, что делает ее полезной для предварительной обработки данных перед обучением нейронных сетей.

Немного о библиотеке **Pandas**:


- **Мощный инструмент для анализа данных:** Pandas предоставляет высокоуровневые структуры данных, такие как DataFrame и Series, которые позволяют удобно и эффективно работать с табличными данными. Это делает Pandas необходимым инструментом для анализа данных в Python.
- **Простота в использовании:** Pandas обладает простым и интуитивно понятным интерфейсом, что делает ее доступной даже для начинающих пользователей. Ее функции позволяют быстро выполнять основные операции с данными, такие как фильтрация, сортировка, группировка и агрегирование.

- **Широкий набор функций:** Pandas предоставляет богатый набор функций для работы с данными, включая чтение и запись данных из различных источников (CSV, Excel, SQL), обработку пропущенных значений, преобразование типов данных, выполнение операций между столбцами и многое другое.
- **Интеграция с другими библиотеками:** Pandas интегрируется с другими популярными библиотеками для анализа данных, такими как NumPy, Matplotlib и SciPy, что делает ее мощным инструментом для создания полноценных аналитических решений.
- **Поддержка сообщества и документация:** Pandas имеет обширную документацию и большое сообщество пользователей и разработчиков, которые предоставляют поддержку, делятся своими знаниями и опытом и разрабатывают дополнительные библиотеки и решения на основе Pandas.

В целом Pandas является неотъемлемым инструментом для работы с данными в Python благодаря своей простоте использования, мощным функциям и широкой поддержке сообщества.



ПРИМЕЧАНИЕ. Эти и другие, не упомянутые, инструменты и библиотеки обеспечивают разработчиков и исследователей мощными средствами для создания, обучения и анализа нейронных сетей в различных областях и приложениях.



Глава 3.

Способы обучения машин

Обучение машин — это процесс, в ходе которого компьютерные системы (модели) обучаются на основе данных с целью выполнения определенной задачи без явного программирования.




Рис. 3.1. Пример обучения на основе опыта, путем подстройки силы связей нейросетей так, чтобы лучше передавать входные сигналы через множество слоев тем нейронам, которые отвечают за различные способы обработки

Рассмотрим далее некоторые из основных способов обучения машин.

3.1. Обучение с учителем (Supervised Learning)

В этом типе обучения модель обучается на помеченных данных, где каждый пример входных данных сопровождается целевой меткой или ответом.

Примеры: **задачи классификации** (где модель должна предсказать категорию или класс для входных данных) и **задачи регрессии** (где модель должна предсказать числовое значение для входных данных).

Вот пример регрессии на Python с использованием библиотеки `scikit-learn`:

ЛИСТИНГ 3.2. Пример линейной регрессии на Python с использованием библиотеки *scikit-learn*

```
from sklearn.linear_model import LinearRegression
import numpy as np

# Входные данные (площадь дома)
X = np.array([[100], [150], [200], [250], [300]])

# Выходные данные (цена дома)
y = np.array([250000, 350000, 450000, 550000, 650000])

# Создание модели линейной регрессии
model = LinearRegression()

# Обучение модели на данных
model.fit(X, y)

# Предсказание цены дома для новых данных
new_house_size = np.array([[180]])
predicted_price = model.predict(new_house_size)
print("Predicted price for a house with size 180 sq.m.:",
      predicted_price)
```

Этот код создает модель линейной регрессии, обучает ее на некоторых обучающих данных (площадь дома и соответствующая цена), а затем использует модель для предсказания цены нового дома на основе его площади.

3.2. Обучение без учителя (Unsupervised Learning)

В этом типе обучения модель обучается на непомеченных данных, и ее целью является выявление скрытых структур или паттернов в данных.

Примеры: кластеризация данных (группировка данных на основе их схожести) и обнаружение аномалий (выявление необычных или аномальных экземпляров данных).

Вот пример кластеризации данных с использованием алгоритма K-means на Python с помощью библиотеки *scikit-learn*:

ЛИСТИНГ 3.3. Пример кластеризации данных с использованием алгоритма K-means на Python с помощью библиотеки *scikit-learn*

```
from sklearn.cluster import KMeans
import numpy as np

# Входные данные (признаки объектов)
X = np.array([[1, 2], [1.5, 1.8], [5, 8], [8, 8], [1, 0.6], [9, 11]])

# Создание модели кластеризации с 2 кластерами
kmeans = KMeans(n_clusters=2)

# Обучение модели на данных
kmeans.fit(X)

# Получение меток кластеров для каждого объекта
labels = kmeans.labels_

# Получение координат центров кластеров
centers = kmeans.cluster_centers_

print("Метки кластеров:", labels)
print("Центры кластеров:", centers)
```

Этот код создает модель кластеризации K-means с двумя кластерами, обучает ее на некоторых данных и выводит метки кластеров для каждого объекта, а также координаты центров кластеров.

3.3. Полуобученное обучение (Semi-supervised Learning)

Это комбинация обучения с учителем и обучения без учителя, где модель обучается на небольшом количестве помеченных данных и большом количестве непомеченных данных.

Этот метод особенно полезен, когда помеченные данные дороги или их трудно получить, но есть доступ к большому объему непомеченных данных. Вот пример полуобученного обучения с использованием библиотеки `scikit-learn` на Python:

ЛИСТИНГ 3.4. Пример полуобученного обучения с использованием библиотеки `scikit-learn` на Python

```
from sklearn.linear_model import SGDClassifier
from sklearn.pipeline import make_pipeline
from sklearn.preprocessing import StandardScaler
import numpy as np

# Некоторые обучающие данные
X_train = np.array([[1, 2], [2, 3], [3, 4], [4, 5]])
y_train = np.array([0, 1, 0, 1])

# Некоторые неразмеченные данные
X_unlabeled = np.array([[1.5, 2.5], [3.5, 4.5]])

# Создание модели полуобученного обучения (Stochastic Gradient
Descent Classifier)
model = make_pipeline(StandardScaler(), SGDClassifier(loss='log',
max_iter=1000))

# Обучение модели на части размеченных данных
model.fit(X_train, y_train)

# Прогнозирование меток классов для неразмеченных данных
predicted_labels = model.predict(X_unlabeled)
print("Predicted labels for unlabeled data:", predicted_labels)
```

Этот код использует метод стохастического градиентного спуска для классификации данных. Модель сначала обучается на части размеченных данных, а затем используется для предсказания меток классов для неразмеченных данных.

3.4. Обучение с подкреплением (Reinforcement Learning)

В этом типе обучения агент взаимодействует с окружающей средой и обучается на основе награды или штрафа за выполнение определенных действий.

Примеры: обучение игровых агентов, автономных роботов и управления процессами.

Вот пример обучения с подкреплением на Python с использованием библиотеки OpenAI Gym:

ЛИСТИНГ 3.5. Пример обучения с подкреплением на Python с использованием библиотеки *OpenAI Gym*

```
import gym

# Создание среды MountainCar-v0
env = gym.make('MountainCar-v0')

# Инициализация Q-таблицы (например, нулями)
Q = {}

# Параметры обучения
alpha = 0.1 # Скорость обучения
gamma = 0.9 # Дисконтирование будущих вознаграждений
epsilon = 0.1 # Эксплорация vs. эксплуатация
```



```

# Количество эпизодов для обучения
episodes = 1000

# Обучение агента
for episode in range(episodes):
    state = env.reset()
    done = False

    while not done:
        # Выбор действия с использованием эпсилон-жадной стратегии
        if state not in Q:
            Q[state] = [0, 0, 0] # Инициализация Q-значений для
            нового состояния
        if np.random.rand() < epsilon:
            action = env.action_space.sample() # Случайное действие
            (эксплорация)
        else:
            action = np.argmax(Q[state]) # Лучшее известное действие
            (эксплуатация)

        # Выполнение действия и получение нового состояния и
        вознаграждения
        new_state, reward, done, _ = env.step(action)

        # Обновление Q-значения для текущей пары состояние-действие
        if new_state not in Q:
            Q[new_state] = [0, 0, 0] # Инициализация Q-значений для
            нового состояния
        Q[state][action] += alpha * (reward + gamma * max(Q[new_
state]) - Q[state][action])

        state = new_state

# Пример использования обученной Q-таблицы для выполнения задачи
state = env.reset()
done = False
while not done:
    action = np.argmax(Q[state]) # Выбор действия на основе
    Q-значений
    new_state, _, done, _ = env.step(action)
    env.render()
# Отображение среды
state = new_state

env.close()
# Закрытие окна среды

```

Этот код использует метод Q-обучения для обучения агента на среде MountainCar-v0 из библиотеки OpenAI Gym. Агент исследует среду, обновляя Q-значения в соответствии с полученными вознаграждениями и выбранными действиями. После обучения агент использует обученную Q-таблицу для выбора действий в среде без дополнительного обучения.

3.5. Обучение активным образом (Active Learning)

В этом методе модель сама выбирает примеры для обучения, которые она считает наиболее информативными для улучшения качества обучения.

Этот метод особенно полезен, когда данных много, а их пометка дорога или трудоемка. Эти методы обучения предоставляют различные подходы к решению задач машинного обучения и могут быть применены в зависимости от конкретной задачи и доступных данных.

Вот пример обучения модели активным образом (Active Learning) на языке Python с использованием библиотеки scikit-learn:

ЛИСТИНГ 3.6. Пример обучения модели активным образом (Active Learning) на языке Python с использованием библиотеки *scikit-learn*

```
from sklearn.datasets import make_classification
from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
import numpy as np

# Генерация синтетических данных
X, y = make_classification(n_samples=1000, n_features=20, n_
classes=2, random_state=42)

# Разделение данных на обучающую и тестовую выборки
```

```

X_train, X_test, y_train, y_test = train_test_split(X, y, test_
size=0.2, random_state=42)

# Инициализация модели
model = RandomForestClassifier(n_estimators=100, random_state=42)

# Обучение модели на первоначальной части данных
initial_sample_size = 100
X_initial, X_remaining, y_initial, y_remaining = train_test_split(X
train, y_train, train_size=initial_sample_size, random_state=42)
model.fit(X_initial, y_initial)

# Оценка качества модели на тестовой выборке
y_pred = model.predict(X_test)
initial_accuracy = accuracy_score(y_test, y_pred)
print("Initial accuracy:", initial_accuracy)

# Активное обучение
query_size = 50
num_queries = 10
for _ in range(num_queries):
    # Выбор примеров для разметки, используя стратегию, например,
    uncertainty sampling
    uncertainty_scores = model.predict_proba(X_remaining)[ :, 0] #
    Неопределенность определяется как вероятность принадлежности к
    классу 0
    query_indices = np.argsort(uncertainty_scores)[:query_size]

    # Обновление обучающей выборки
    X_query = X_remaining[query_indices]
    y_query = y_remaining[query_indices]
    X_initial = np.vstack([X_initial, X_query])
    y_initial = np.hstack([y_initial, y_query])

    # Удаление выбранных примеров из оставшейся выборки
    X_remaining = np.delete(X_remaining, query_indices, axis=0)
    y_remaining = np.delete(y_remaining, query_indices)

    # Переобучение модели на расширенной обучающей выборке
    model.fit(X_initial, y_initial)

    # Оценка качества модели на тестовой выборке
    y_pred = model.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)
    print("Accuracy after {} queries: {:.3f}".format((_ + 1) *
query_size, accuracy))

```

Этот код демонстрирует процесс активного обучения. Модель обучается на начальной части данных, а затем происходит выбор примеров для разметки и их добавление в обучающую выборку, с последующим переобучением модели.

В данном примере используется стратегия **uncertainty sampling**, которая выбирает примеры с наибольшей неопределенностью (например, с наименьшей вероятностью класса).

3.6. Генетическое обучение

Генетическое обучение — это метод машинного обучения, который использует концепции и принципы генетики и эволюции для создания и оптимизации моделей.

В этом подходе используется процесс эволюции, где популяция моделей проходит через серию эволюционных шагов, чтобы достичь оптимальной производительности для решения задачи.

Вот пример простого генетического алгоритма на языке Python:

ЛИСТИНГ 3.7. Пример генетического алгоритма для решения задачи оптимизации бинарных строк на языке Python

```
import numpy as np

# Функция приспособленности (fitness function)
def fitness_function(solution):
    target = np.array([1, 1, 0, 1, 0, 0, 1, 1, 0, 0])
    # Целевой массив
    return np.sum(solution == target)
# Возвращает количество совпадающих элементов

# Инициализация популяции
def initialize_population(pop_size, chromosome_length):
    return np.random.randint(2, size=(pop_size, chromosome_length))

# Отбор особей для скрещивания
```

```

def select_parents(population, fitness_values):
    sorted_indices = np.argsort(fitness_values)[::-1] # Сортируем по
убыванию приспособленности
    return population[sorted_indices[:2]] # Возвращаем двух лучших особей

# Скрещивание (одноточечное)
def crossover(parent1, parent2):
    crossover_point = np.random.randint(len(parent1))
    child1 = np.concatenate((parent1[:crossover_point], parent2[crossover_
point:]))
    child2 = np.concatenate((parent2[:crossover_point], parent1[crossover_
point:]))
    return child1, child2

# Мутация
def mutate(child, mutation_rate):
    for i in range(len(child)):
        if np.random.rand() < mutation_rate:
            child[i] = 1 - child[i] # Инвертируем бит
    return child

# Генетический алгоритм
def genetic_algorithm(pop_size, chromosome_length, generations, mutation_
rate):
    population = initialize_population(pop_size, chromosome_length)
    for generation in range(generations):
        fitness_values = np.array([fitness_function(individual) for individual
in population])
        parents = select_parents(population, fitness_values)
        offspring = []
        for _ in range(pop_size // 2):
            child1, child2 = crossover(parents[0], parents[1])
            child1 = mutate(child1, mutation_rate)
            child2 = mutate(child2, mutation_rate)
            offspring.append(child1)
            offspring.append(child2)
        population = np.array(offspring)
        best_solution_index = np.argmax(fitness_values)
        best_solution_fitness = fitness_values[best_solution_index]
        best_solution = population[best_solution_index]
        return best_solution, best_solution_fitness

# Параметры генетического алгоритма
pop_size = 20
chromosome_length = 10
generations = 100
mutation_rate = 0.1

```

```
# Запуск генетического алгоритма
best_solution, best_fitness = genetic_algorithm(pop_size, chromosome_length,
generations, mutation_rate)

print("Best solution:", best_solution)
print("Best fitness:", best_fitness)
```

Этот пример демонстрирует генетический алгоритм для решения задачи оптимизации бинарных строк. Алгоритм инициализирует случайную популяцию, оценивает ее приспособленность, выбирает лучших особей для скрещивания, скрещивает, подвергает их мутации и повторяет процесс на протяжении нескольких поколений. В результате получается лучшая особь (наиболее подходящая бинарная строка) с высокой приспособленностью.

Вот основные принципы и компоненты генетического обучения:

- **Популяция:** начальная популяция состоит из множества случайно созданных моделей или генетических конфигураций, представляющих различные варианты решения задачи.
- **Функция приспособленности:** для оценки производительности каждой модели используется функция приспособленности, которая оценивает, насколько хорошо модель справляется с поставленной задачей.
- **Отбор:** на основе значений функции приспособленности производится отбор лучших моделей, которые будут использоваться для создания следующего поколения.
- **Скрещивание** (кроссинговер): выбранные модели совершают скрещивание, в результате которого создаются новые модели путем комбинации генетических характеристик (параметров) родительских моделей.
- **Мутация:** некоторые модели в следующем поколении могут подвергаться мутации, которая способна привести к случайным изменениям параметров. Это помогает исследовать новые области пространства решений.
- **Оценка:** новое поколение моделей оценивается с использованием функции приспособленности, и процесс отбора, скрещивания и мутации повторяется до тех пор, пока не будет достигнуто определенное условие остановки (например, достаточное количество поколений или достижение определенного уровня производительности).

Генетическое обучение может быть эффективным методом для оптимизации моделей в случаях, когда пространство поиска решений слишком велико или нелинейно, а также для создания новых алгоритмов, адаптированных к конкретным условиям или задачам. Однако этот метод может быть вычислительно затратным из-за необходимости многократного обучения моделей на каждой итерации эволюции.

3.7. Метод обратного распространения ошибки (Backpropagation)

Метод обратного распространения ошибки — это основной алгоритм обучения нейронных сетей, который используется для коррекции параметров модели на основе вычисленной ошибки прогнозирования.

Этот метод позволяет эффективно обучать нейронные сети для выполнения различных задач, таких как классификация, регрессия и другие.

Вот пример метода обратного распространения ошибки на Python:

ЛИСТИНГ 3.8. Пример метода обратного распространения ошибки на Python

```
import numpy as np

# Пример функции активации (сигмоид)
def sigmoid(x):
    return 1 / (1 + np.exp(-x))

# Пример производной функции активации
def sigmoid_derivative(x):
    return x * (1 - x)

# Пример реализации метода обратного распространения ошибки
def backpropagation(input_data, output_data, learning_rate, epochs):
    input_layer_size = input_data.shape[1]
```

```

hidden_layer_size = 4
output_layer_size = output_data.shape[1]

# Инициализация весов сети
weights_input_hidden = np.random.uniform(size=(input_layer_size,
hidden_layer_size))
weights_hidden_output = np.random.uniform(size=(hidden_layer_size,
output_layer_size))

for epoch in range(epochs):
    # Прямое распространение
    hidden_layer_input = np.dot(input_data, weights_input_hidden)
    hidden_layer_output = sigmoid(hidden_layer_input)
    output_layer_input = np.dot(hidden_layer_output, weights_
hidden_output)
    predicted_output = sigmoid(output_layer_input)

    # Вычисление ошибки
    output_error = output_data - predicted_output
    if epoch % 10000 == 0:
        print('Error:', np.mean(np.abs(output_error)))

    # Обратное распространение
    d_predicted_output = output_error *
sigmoid_derivative(predicted_output)
    output_layer_error =
d_predicted_output.dot(weights_hidden_output.T)
    d_hidden_layer_output = output_layer_error * sigmoid_
derivative(hidden_layer_output)

    # Обновление весов
    weights_hidden_output +=
hidden_layer_output.T.dot(d_predicted_output) * learning_rate
    weights_input_hidden +=
input_data.T.dot(d_hidden_layer_output) * learning_rate

    return weights_input_hidden, weights_hidden_output

# Пример использования метода обратного распространения ошибки
input_data = np.array([[0, 0],
                        [0, 1],
                        [1, 0],
                        [1, 1]])

output_data = np.array([[0],
                        [1],
                        [1],
                        [0]])

```



```
learning_rate = 0.1
epochs = 100000

weights_input_hidden, weights_hidden_output =
backpropagation(input_data, output_data, learning_rate, epochs)
print("Weights Input to Hidden:\n", weights_input_hidden)
print("Weights Hidden to Output:\n", weights_hidden_output)
```

Этот код демонстрирует реализацию метода обратного распространения ошибки для обучения нейронной сети на простой задаче логического XOR.

Вот как работает метод обратного распространения ошибки:

- **Прямое распространение (Forward Propagation):** на первом этапе данные подаются на вход модели, и происходит прямое распространение сигнала от входных слоев к выходным. Каждый нейрон в сети принимает входные данные, вычисляет свой выход, применяя функцию активации к сумме взвешенных входов, и передает этот выход следующему слою.
- **Вычисление ошибки (Error Calculation):** после прямого распространения оценивается разница между предсказанными значениями и ожидаемыми целевыми значениями. Это создает функцию потерь, которая оценивает, насколько хорошо модель справилась с задачей.
- **Обратное распространение (Backward Propagation):** на этом этапе ошибка сети обратно распространяется от выходного слоя к входному с целью коррекции параметров модели. Каждый параметр модели (веса и смещения) получает градиент функции потерь по отношению к нему с помощью правила цепочки, и параметры обновляются в направлении, противоположном градиенту, чтобы минимизировать функцию потерь.
- **Обновление параметров (Parameters Update):** после вычисления градиентов их используют для обновления параметров модели с использованием оптимизационного алгоритма, такого как стохастический градиентный спуск (SGD) или его вариации (например, Adam, RMSprop). Этот процесс повторяется на нескольких эпохах (итерациях) обучения до тех пор, пока модель не достигнет удовлетворительного уровня производительности.

Метод обратного распространения ошибки является основой обучения нейронных сетей и позволяет эффективно корректировать параметры модели, чтобы минимизировать ошибку и улучшить ее производительность в решении задач машинного обучения.

3.8. Обучение на основе конкуренции

Обучение на основе конкуренции — это метод машинного обучения, который использует принцип конкуренции между моделями или агентами для улучшения их производительности. В этом методе модели или агенты соревнуются между собой за ресурсы или вознаграждения, что способствует их улучшению и сходимости к оптимальным решениям.

Вот пример простого алгоритма конкурентного обучения на Python с использованием метода Q-обучения:

ЛИСТИНГ 3.9. Пример простого алгоритма конкурентного обучения на Python, который демонстрирует конкурентное обучение двух агентов в простой среде с двумя возможными действиями и двумя возможными состояниями

```
import numpy as np

# Класс для агента
class Agent:
    def __init__(self, num_actions):
        self.num_actions = num_actions
        self.q_values = np.zeros(num_actions)

    def select_action(self):
        return np.argmax(self.q_values)
```

```

def update_q_values(self, action, reward, learning_rate):
    self.q_values[action] += learning_rate * reward

# Функция среды
def environment(agent1, agent2, num_episodes, max_steps, learning_rate):
    for episode in range(num_episodes):
        state = np.random.randint(0, 2) # Генерация случайного
начального состояния
        for step in range(max_steps):
            # Выбор действия от обоих агентов
            action1 = agent1.select_action()
            action2 = agent2.select_action()

            # Награда за выбор действий
            if state == 0: # Если состояние 0
                if action1 == 0 and action2 == 0: # Если оба агента
выбирают действие 0
                    reward1, reward2 = 1, 1
                else:
                    reward1, reward2 = 0, 0
            else: # Если состояние 1
                if action1 == 1 and action2 == 1: # Если оба агента
выбирают действие 1
                    reward1, reward2 = 1, 1
                else:
                    reward1, reward2 = 0, 0

            # Обновление Q-значений агентов
            agent1.update_q_values(action1, reward1, learning_rate)
            agent2.update_q_values(action2, reward2, learning_rate)

            # Изменение состояния
            state = 1 - state
            # Переход к следующему состоянию

# Создание двух агентов
agent1 = Agent(num_actions=2)
agent2 = Agent(num_actions=2)

# Настройка параметров обучения
num_episodes = 1000
max_steps = 100
learning_rate = 0.1

# Запуск среды и обучение агентов
environment(agent1, agent2, num_episodes, max_steps, learning_rate)

# Вывод Q-значений обученных агентов

```

```
print("Q-values of Agent 1:", agent1.q_values)
print("Q-values of Agent 2:", agent2.q_values)
```

Этот пример демонстрирует **конкурентное обучение двух агентов** в простой среде с двумя возможными действиями и двумя возможными состояниями. Агенты обновляют свои Q-значения на основе выбранных действий и полученных наград.

Вот некоторые из основных принципов обучения на основе конкуренции:

- **Соревнование за ресурсы или награды.** Модели или агенты конкурируют за доступ к ресурсам или за получение максимального вознаграждения в рамках определенной задачи. Это может включать соревнование за право предложения ответа на вопрос, за захват территории, за выполнение задачи с наилучшим качеством и т. д.
- **Обучение на основе обратной связи.** Конкуренция способствует обмену информацией между моделями или агентами, что позволяет им учиться на основе опыта и ошибок друг друга. Это может включать в себя обмен знаниями о лучших стратегиях, техниках или методах решения задачи, что помогает улучшить производительность всей группы.
- **Итеративный процесс улучшения.** Модели или агенты обновляют свои стратегии и поведение на основе полученного опыта и обратной связи, что позволяет им с каждым шагом приближаться к оптимальному решению. Это может включать в себя эволюционные алгоритмы, где лучшие решения передаются в следующее поколение, или обучение с подкреплением, где модель получает вознаграждение или штраф за свои действия.
- **Применение в различных областях.** Обучение на основе конкуренции может быть применено в различных областях, таких как игровая теория, оптимизация, обучение с подкреплением, эволюционные вычисления и другие. Оно может быть использовано для решения задачи оптимизации, для создания адаптивных алгоритмов решения проблем или для модели-

рования взаимодействий в различных социальных и экономических сценариях.

Обучение на основе конкуренции предоставляет эффективный и мощный подход к улучшению производительности моделей или агентов путем стимулирования соревнования и обмена информацией между ними. Этот метод может быть особенно полезен в ситуациях, где существует неопределенность или когда решение задачи требует адаптивности и улучшения со временем.

3.9. Обучение ансамблем

Обучение ансамблем — это метод машинного обучения, который объединяет несколько моделей (называемых базовыми моделями или участниками) для получения более точного и стабильного прогноза, чем могли бы дать отдельные модели.

Вот пример на Python, демонстрирующий обучение ансамблем моделей машинного обучения с помощью метода бэггинга (bootstrap aggregating) с использованием библиотеки `scikit-learn`:

ЛИСТИНГ 3.10. Пример на Python, демонстрирующий обучение ансамблем моделей машинного обучения с помощью метода бэггинга (bootstrap aggregating) с использованием библиотеки `scikit-learn`

```
from sklearn.datasets import load_iris
from sklearn.model_selection import train_test_split
from sklearn.ensemble import BaggingClassifier
from sklearn.tree import DecisionTreeClassifier
from sklearn.metrics import accuracy_score
```

```
# Загрузка датасета Iris
```

```
iris = load_iris()
X = iris.data
y = iris.target

# Разделение данных на обучающий и тестовый наборы
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Определение базовой модели (в данном случае решающего дерева)
base_model = DecisionTreeClassifier()

# Определение ансамбля моделей с помощью бэггинга
bagging_model = BaggingClassifier(base_model, n_estimators=10,
random_state=42)

# Обучение ансамбля
bagging_model.fit(X_train, y_train)

# Предсказание на тестовом наборе
y_pred = bagging_model.predict(X_test)

# Оценка точности модели
accuracy = accuracy_score(y_test, y_pred)
print("Accuracy of Bagging Ensemble:", accuracy)
```

В этом примере используется датасет Iris, а базовая модель — решающее дерево. Метод бэггинга применяется для создания ансамбля из 10 решающих деревьев. Каждое дерево обучается на случайной подвыборке данных (с повторениями) из обучающего набора. После обучения ансамбль используется для предсказания классов на тестовом наборе, и оценивается точность предсказания.

Вот основные принципы и преимущества обучения ансамблями:

- **Разнообразие моделей.** В ансамбле используются различные модели или одинаковые модели, обученные на разных наборах данных или с использованием разных алгоритмов обучения. Разнообразие моделей позволяет улавливать различные аспекты структуры и зависимостей в данных, что способствует улучшению обобщающей способности ансамбля.
- **Комбинация прогнозов.** Прогнозы отдельных моделей объединяются в единый ответ, например путем голосования большинства или усредне-

ния. Это позволяет уменьшить вариабельность прогнозов и сделать более стабильные и надежные предсказания.

- **Улучшение обобщающей способности.** Ансамбль может уменьшить склонность к переобучению, особенно если базовые модели имеют различные источники ошибки или используются различные алгоритмы обучения. Это позволяет повысить обобщающую способность модели и получить более точные прогнозы на новых данных.
- **Применение различных методов агрегации.** Ансамбль может использовать различные методы агрегации прогнозов, такие как взвешенное голосование, стекинг или бэггинг, чтобы улучшить качество прогнозов. Это позволяет адаптировать ансамбль к конкретной задаче и максимизировать его производительность.
- **Применение в различных областях.** Обучение ансамблем широко используется в различных областях машинного обучения, включая классификацию, регрессию, кластеризацию и др. Оно может быть применено к различным типам данных и задачам, что делает его универсальным методом для улучшения качества прогнозов в различных приложениях. Обучение ансамблем представляет собой мощный метод для улучшения качества прогнозов путем объединения нескольких моделей, что позволяет получить более точные, стабильные и обобщающие результаты на различных задачах машинного обучения.

3.10. Когнитивный метод

Когнитивный метод обучения может быть применен в обучении машин, хотя его применение может иметь некоторые особенности из-за различий между человеческим и машинным интеллектом. Этот метод направлен на создание моделей, способных имитировать процессы мышления человека.

Один из примеров такого метода — использование **глубоких нейронных сетей**, которые могут анализировать и интерпретировать данные, подобно тому, как это делает человеческий мозг.

Ниже приведен пример использования библиотеки TensorFlow для создания глубокой нейронной сети:

ЛИСТИНГ 3.11. Пример использования библиотеки *TensorFlow* для создания глубокой нейронной сети с использованием набора данных MNIST

```
import tensorflow as tf
from tensorflow.keras import layers, models

# Загрузка данных (пример MNIST)
mnist = tf.keras.datasets.mnist
(train_images, train_labels), (test_images, test_labels) = mnist.load_data()

# Нормализация данных
train_images = train_images/255.0
test_images = test_images/255.0

# Определение модели нейронной сети
model = models.Sequential([
    layers.Flatten(input_shape=(28, 28)),
    layers.Dense(128, activation='relu'),
    layers.Dropout(0.2),
    layers.Dense(10, activation='softmax')
])

# Компиляция модели
model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])

# Обучение модели
model.fit(train_images, train_labels, epochs=5)

# Оценка точности модели на тестовом наборе данных
test_loss, test_acc = model.evaluate(test_images, test_labels)
print('Test accuracy:', test_acc)
```


В этом примере используется набор данных MNIST, содержащий изображения рукописных цифр от 0 до 9.

Нейронная сеть состоит из нескольких слоев: входной слой принимает изображения (28×28 пикселей) и преобразует их в одномерный вектор, после чего идут полносвязные слои с функцией активации ReLU и слой с функцией активации softmax в конце, который предсказывает вероятности принадлежности к каждому классу.

Модель компилируется с использованием оптимизатора Adam и функции потерь `sparse_categorical_crossentropy`. После обучения оценивается точность модели на тестовом наборе данных.

Вот несколько способов, как можно использовать когнитивный подход в обучении машин:

- **Активное обучение моделей:** подобно тому, как человек активно участвует в процессе обучения, машины могут быть обучены с использованием методов, которые стимулируют их активное участие в процессе обработки информации и принятия решений. Это может включать в себя обучение с подкреплением, где агенты принимают решения и получают обратную связь на основе своих действий.
- **Моделирование когнитивных процессов:** многие когнитивные процессы, такие как внимание, память и решение проблем, могут быть моделированы и реализованы в машинных алгоритмах. Например, можно создать модели, которые имитируют работу человеческого внимания при анализе и классификации данных.
- **Адаптивное обучение:** модели машинного обучения могут быть обучены с учетом индивидуальных потребностей и способностей, аналогично тому, как когнитивный подход к обучению учитывает индивидуальные особенности учеников. Это может включать в себя персонализацию обучения и адаптацию моделей к конкретным сценариям использования.
- **Метакогнитивные навыки:** модели машинного обучения могут быть обучены различным стратегиям оценки и управления своими решениями, аналогично тому, как люди могут регулировать свой процесс обучения с

помощью метакогнитивных навыков. Это может помочь моделям адаптироваться к изменяющимся условиям и улучшать свою производительность с течением времени.

Хотя применение когнитивного метода обучения в машинном обучении имеет свои особенности и ограничения, оно может быть полезным для развития более гибких, адаптивных и интеллектуальных систем.

Использование **принципов когнитивного обучения** в машинном обучении может помочь создать модели, которые лучше адаптированы к сложным и непредсказуемым ситуациям в реальном мире.

3.11. Обучение по претендентам (Protégé Learning)

Обучение по претендентам — это метод машинного обучения, который использует экспертные знания и рекомендации специалистов (претендентов) для обучения моделей. В этом подходе модель обучается на основе знаний, которые предоставляют эксперты в определенной области, что позволяет улучшить качество обучения и прогнозирования.

Метод обучения по претендентам (англ. *hill climbing*) является оптимизационным методом, который заключается в **поиске оптимального решения** путем последовательного изменения текущего решения в направлении улучшения.

Ниже приведен простой пример реализации метода обучения по претендентам для решения задачи оптимизации:

ЛИСТИНГ 3.12. Пример реализации метода обучения по претендентам для решения задачи оптимизации

```
import numpy as np

# Функция, которую мы хотим оптимизировать (пример)
def objective_function(x):
    return -(x ** 2)

# Минимизируем функцию  $-x^2$ 

# Метод обучения по претендентам (Hill Climbing)
def hill_climbing(objective_function, num_iterations, step_size=0.1):
    # Начальное решение
    current_solution = np.random.uniform(-10, 10)
    # Случайное начальное значение
    current_score = objective_function(current_solution)

    # Поиск оптимального решения
    for _ in range(num_iterations):
        # Генерация нового претендента в окрестности текущего решения
        new_solution = current_solution + np.random.uniform(-step_size, step_size)
        new_score = objective_function(new_solution)

        # Если новое решение лучше, то обновляем текущее
        if new_score > current_score:
            current_solution = new_solution
            current_score = new_score

    return current_solution, current_score

# Параметры метода обучения
num_iterations = 1000
step_size = 0.1

# Запуск метода обучения и вывод результата
best_solution, best_score = hill_climbing(objective_function, num_iterations, step_size)
print("Best solution:", best_solution)
print("Best score:", best_score)
```

Этот пример демонстрирует применение метода обучения по претендентам для поиска оптимального решения для заданной функции. Мы ищем минимум функции $-x^2$ с помощью метода обучения по претендентам.

Алгоритм начинает со случайного начального решения и последовательно изменяет его в направлении улучшения.

В результате получаем оптимальное решение и его значение функции.

Вот основные принципы и характеристики обучения по претендентам:

- **Экспертные знания:** в обучении по претендентам используются знания и опыт экспертов в области, в которой обучается модель. Эксперты могут предоставить информацию о правильных ответах, важных признаках и закономерностях в данных, а также рекомендации по принятию решений.
- **Обучение с учителем:** обучение по претендентам часто осуществляется в рамках задач обучения с учителем, где модель обучается на маркированных данных с предоставленными экспертами ответами. Это позволяет модели учиться на основе правильных ответов и знаний экспертов.
- **Итеративный процесс:** обучение по претендентам часто включает в себя итеративный процесс взаимодействия с экспертами, где модель обучается на основе предоставленных знаний, а затем получает обратную связь от экспертов для улучшения своей производительности. Этот процесс может повторяться до тех пор, пока модель не достигнет удовлетворительного уровня производительности.
- **Использование дополнительной информации:** кроме экспертных знаний, модели могут быть обучены с использованием других источников информации, таких как маркированные данные, наблюдения или примеры из реального мира. Это позволяет модели учиться на основе различных источников информации и расширять свои знания и навыки.
- **Применение в различных областях:** обучение по претендентам может быть применено в различных областях машинного обучения, включая медицину, финансы, науку о данных и другие. Оно может быть полезным для улучшения качества моделей и увеличения их прозрачности и интерпретируемости.

Обучение по претендентам представляет собой эффективный метод машинного обучения, который использует экспертные знания для обучения моделей и улучшения их производительности. Этот подход может быть особенно полезным в случаях, когда доступ к экспертам и их знаниям является ключевым для решения задачи.

3.12. Гибридное обучение машин

Гибридное обучение — это метод, который комбинирует различные подходы и техники машинного обучения для достижения более высокой производительности и улучшения результатов.

В гибридном подходе объединяются сильные стороны различных методов, чтобы компенсировать их слабые стороны и раскрыть их полный потенциал.

Ниже приведен пример гибридного обучения, включающего в себя комбинацию нейронной сети и метода опорных векторов (Support Vector Machine, SVM) на языке Python с использованием библиотеки *scikit-learn*:

ЛИСТИНГ 3.13. Пример гибридного обучения, включающего в себя комбинацию нейронной сети и метода опорных векторов (Support Vector Machine, SVM) на языке Python с использованием библиотеки *scikit-learn*

```
from sklearn.datasets import load_iris
from sklearn.model_selection import train_test_split
from sklearn.svm import SVC
from sklearn.neural_network import MLPClassifier
from sklearn.ensemble import VotingClassifier
from sklearn.metrics import accuracy_score
```

```
# Загрузка датасета Iris
iris = load_iris()
X = iris.data
y = iris.target

# Разделение данных на обучающий и тестовый наборы
X_train, X_test, y_train, y_test = train_test_split(X, y, test_
size=0.2, random_state=42)

# Определение моделей для гибридного обучения
svm_model = SVC(kernel='linear', probability=True)
nn_model = MLPClassifier(hidden_layer_sizes=(100,), max_iter=1000)

# Объединение моделей в голосующий классификатор
hybrid_model = VotingClassifier(estimators=[('svm', svm_model),
('nn', nn_model)], voting='soft')

# Обучение гибридной модели
hybrid_model.fit(X_train, y_train)

# Предсказание на тестовом наборе
y_pred = hybrid_model.predict(X_test)

# Оценка точности модели
accuracy = accuracy_score(y_test, y_pred)
print("Accuracy of Hybrid Model:", accuracy)
```

В этом примере модели SVM и нейронная сеть (MLPClassifier) объединяются в голосующий классификатор (VotingClassifier) с использованием метода голосования soft. Каждая модель вносит свой вклад в окончательное решение, а soft-голосование учитывает вероятности принадлежности к классам, предоставляемые каждой моделью. После обучения гибридной модели оценивается ее точность на тестовом наборе данных.

Вот некоторые ключевые аспекты гибридного обучения машин:

- **Комбинация различных методов:** гибридное обучение машин объединяет различные методы, такие как нейронные сети, деревья решений, генетические алгоритмы и другие, в единую систему. Это позволяет использовать сильные стороны каждого метода, чтобы компенсировать их слабые стороны и достичь лучших результатов.

- **Использование различных типов данных и признаков:** гибридное обучение может включать в себя обработку различных типов данных, таких как тексты, числа, изображения и временные ряды, и использовать различные признаки для улучшения качества моделей. Это позволяет модели учитывать разнообразные аспекты данных и достигать более полного понимания задачи.
- **Комбинирование экспертных знаний и данных:** гибридное обучение может включать в себя объединение экспертных знаний с данными, собранными из наблюдений, для создания более точных и интерпретируемых моделей. Это позволяет использовать знания и опыт экспертов для улучшения производительности моделей и увеличения их прозрачности.
- **Использование ансамблей моделей:** в гибридном обучении могут использоваться ансамбли моделей, объединяющие результаты нескольких моделей для получения более стабильных и точных прогнозов. Это позволяет снизить вариативность и повысить уверенность в результатах моделей.
- **Применение в различных областях:** гибридное обучение машин может быть применено в различных областях, таких как здравоохранение, финансы, транспорт, энергетика и другие. Этот подход может быть особенно полезным в сложных и изменчивых средах, где нет одного универсального метода решения задачи.

Гибридное обучение машин представляет собой эффективный подход, который позволяет использовать различные методы и техники машинного обучения для достижения лучших результатов. Этот метод активно исследуется и применяется в различных областях для решения сложных задач и повышения производительности моделей.

В настоящее время процессы обучения машин находятся на пике своего развития и широко применяются в различных областях, включая медицину, финансы, автомобильную промышленность, рекламу, сельское хозяйство, игровую индустрию и многое другое.

3.13. Настоящее и перспективы способов обучения машин

Сейчас достигнуты определенные успехи в машинном обучении, позволяющие применять нейросети в различных областях человеческой деятельности, от компьютерного зрения и обработки естественного языка до биоинформатики и финансов.

Каждый день совершенствуются способы обучения, о которых было упомянуто в нашем пособии, возникают новые направления, что приводит к созданию еще более эффективных и инновационных методов и алгоритмов их использования.

Важно продолжать исследования в области машинного обучения с целью расширения границ знаний и создания новых методов, способных решать более сложные и интересные задачи.

Такой подход поможет ускорить прогресс в машинном обучении и повысить его применимость в различных областях науки и промышленности.

Рассмотрим ряд важных тенденций и перспектив в области обучения машин:

- **Увеличение объема и разнообразия данных:** с появлением большого количества данных и развитием технологий их сбора процессы обучения машин становятся все более точными и эффективными.
- **Развитие глубокого обучения и нейронных сетей:** глубокое обучение и нейронные сети сейчас играют ключевую роль во многих приложениях машинного обучения, обеспечивая значительный прогресс в области распознавания образов, естественного языка, обработки изображений, управления данными и других областях.
- **Продвижение автоматизации и автономности:** процессы обучения машин активно развиваются в направлении создания автономных систем, способных принимать решения и действовать в реальном времени без человеческого вмешательства.

- **Обучение с подкреплением и обучение на основе данных:** обучение с подкреплением становится все более популярным и применяется в различных областях, в то время как обучение на основе данных продолжает развиваться для анализа больших объемов информации и извлечения ценных знаний из данных.
- **Продолжение исследований в области обучения человеко-машинных систем:** исследования в области обучения человеко-машинных систем, где машины и люди работают вместе для решения сложных задач, представляют собой важную перспективу для будущего развития машинного обучения.

В целом процессы обучения машин продолжают развиваться и предоставлять широкие возможности для улучшения эффективности, точности и автономности систем, а также для создания новых инновационных решений для различных областей применения.



Рис. 3.14. Пример генерации киборга. Нейросеть Leonardo

Развитие новых методов и алгоритмов, а также улучшение доступности данных и вычислительных ресурсов будут продолжать играть ключевую роль в будущем развитии машинного обучения.

Улучшение процессов обучения машин — это весьма важная задача, которая может привести к созданию более эффективных и интеллектуальных систем.


Вот несколько пожеланий по этому поводу:

- **Развитие интерпретируемых моделей:** было бы замечательно, если бы мы могли создавать модели, которые не только достигают высокой точности, но и легко интерпретируются и объясняются. Это помогло бы сделать решения нашей модели более прозрачными и понятными для пользователей и специалистов в области.
- **Улучшение обучения с малым количеством данных:** важно развивать методы обучения машин, которые могут обучаться с небольшими объемами данных, особенно в случаях, когда данных недостаточно или дорого собирать.
- **Автоматизация процессов предобработки данных:** процесс предобработки данных часто требует значительных усилий и времени. Улучшение методов автоматизации предобработки данных позволит существенно ускорить процесс разработки моделей и повысить их эффективность.
- **Развитие методов обучения с подкреплением:** обучение с подкреплением обещает создать автономные и интеллектуальные системы. Дальнейшее развитие этого направления поможет создать более адаптивные и самообучающиеся алгоритмы.
- **Улучшение эффективности обучения на гетерогенных данных:** существует множество типов данных с различными структурами и характеристиками. Развитие методов, которые могут эффективно работать с гете-

рогенными данными, позволит создавать более универсальные и гибкие модели.

- **Учет этических и социальных аспектов:** при разработке новых методов обучения машин важно учитывать этические и социальные аспекты. Мы должны стремиться создавать модели, которые справедливо и непредвзято учитывают разнообразие и потребности наших обществ.

Возможно, эти пожелания помогут стимулировать развитие машинного обучения более эффективно и ответственно.



Глава 4.

Использование нейросетей. Практическое применение

4.1. Распознавание изображений.

Классификация изображений. Сегментация изображений. Создание изображений, видео

Распознавание изображений искусственным интеллектом — это процесс анализа и интерпретации визуальной информации с использованием алгоритмов машинного обучения и нейронных сетей.

Основные цели этого процесса — автоматизированное определение и классификация объектов, образов и паттернов на изображениях.




Рис. 4.1. Распознавание изображений

Вот ключевые аспекты и методы распознавания изображений AI:

- **Предобработка изображений:** первый шаг в распознавании изображений — это предобработка, включающая в себя изменение размера изображения, нормализацию яркости и контраста, а также фильтрацию шумов.
- **Использование сверточных нейронных сетей (CNN):** CNN — это тип нейронных сетей, специально разработанный для анализа визуальной информации. Они автоматически изучают характеристики и признаки изображений, позволяя распознавать объекты на них.
- **Обучение с учителем:** в большинстве случаев распознавание изображений происходит в рамках обучения с учителем, где модель обучается на маркированных данных, где каждому изображению присвоен соответствующий класс или метка.
- **Обнаружение объектов и сегментация:** помимо классификации объектов, AI также может обнаруживать объекты на изображениях и выполнять сегментацию, то есть разделение изображения на отдельные части, соответствующие различным объектам или областям.
- **Использование предварительно обученных моделей:** для задач распознавания изображений часто используются предварительно обученные модели, которые обучены на больших наборах данных, таких как ImageNet. Эти модели могут быть дообучены или настроены для конкретной задачи.
- **Применение в различных областях:** распознавание изображений находит применение во многих областях, таких как медицина (диагностика заболеваний по медицинским изображениям), автомобильная промышленность (автономные транспортные средства), безопасность (видеонаблюдение), исследования поиска и рекомендации (анализ изображений для выявления паттернов и трендов).

Распознавание изображений искусственным интеллектом имеет огромный потенциал и широко применяется в различных областях, способствуя автоматизации процессов и улучшению качества принимаемых решений.

Рассмотрим каждый из этих аспектов.

4.1.1. Классификация изображений

Классификация изображений — это процесс определения категории или класса, к которому принадлежит изображение.

Для классификации изображений AI использует нейронные сети, особенно сверточные нейронные сети (CNN), которые обучаются на больших наборах данных с маркированными изображениями.

Вот пример классификации изображения с использованием сверточной нейронной сети на языке Python с использованием библиотеки TensorFlow:

ЛИСТИНГ 4.2. Пример классификации изображения с использованием сверточной нейронной сети

```
import tensorflow as tf
from tensorflow.keras import layers, models

# Загрузка датасета (например, MNIST)
mnist = tf.keras.datasets.mnist
(train_images, train_labels), (test_images, test_labels) = mnist.load_data()

# Масштабирование значений пикселей к диапазону [0, 1]
train_images, test_images = train_images / 255.0, test_images / 255.0

# Определение архитектуры нейронной сети
model = models.Sequential([
    layers.Conv2D(32, (3, 3), activation='relu', input_shape=(28, 28, 1)),
    layers.MaxPooling2D((2, 2)),
    layers.Conv2D(64, (3, 3), activation='relu'),
    layers.MaxPooling2D((2, 2)),
    layers.Conv2D(64, (3, 3), activation='relu'),
    layers.Flatten(),
```



```
layers.Dense(64, activation='relu'),
layers.Dense(10, activation='softmax')
])

# Компиляция модели
model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])

# Обучение модели
model.fit(train_images.reshape(-1, 28, 28, 1), train_labels, epochs=5)

# Оценка точности на тестовом наборе данных
test_loss, test_acc = model.evaluate(test_images.reshape(-1, 28, 28,
1), test_labels)
print('Test accuracy:', test_acc)
```

Этот код создает сверточную нейронную сеть, которая классифицирует изображения из набора данных MNIST, содержащего рукописные цифры.

После обучения модель может классифицировать новые изображения, определяя, к какому классу они относятся.

4.1.2. Сегментация изображений

Сегментация изображений — это процесс разделения изображения на несколько сегментов или областей, каждая из которых содержит объекты с однородными характеристиками, такими как цвет, текстура, яркость и т. д.

Цель сегментации — выделить объекты или интересующие области на изображении для более детального анализа или обработки.

Виды сегментации изображений:

- **Семантическая сегментация:** этот тип сегментации заключается в присвоении каждому пикселю изображения определенной метки класса или категории. Например, на изображении человека на фоне леса каждый пиксель может быть помечен как "человек", "дерево", "трава" и т. д.
- **Инстанс-сегментация:** в отличие от семантической сегментации, инстанс-сегментация позволяет проводить различия между разными экземплярами одного класса. Например, если на изображении несколько людей, каждый человек будет иметь свой уникальный идентификатор.
- **Детекция объектов:** это подтип инстанс-сегментации, который также включает определение границ объектов. В этом случае, помимо выделения объектов, каждый объект также ограничивается прямоугольником или маской.
- **Региональная сегментация:** в этом типе сегментации изображение разделяется на регионы на основе однородности характеристик, таких как цвет, текстура или яркость. Каждый регион может содержать несколько объектов.
- **Контурная сегментация:** этот тип сегментации сосредотачивается на выделении границ объектов на изображении без присвоения меток классов. Обычно это делается путем выделения контуров объектов.

Сегментация изображений используется для разнообразных целей, в том числе:

- В *медицине*: для анализа медицинских изображений — выделения опухолей и других патологий, определения объемов тканей, при решении задач хирургии с использованием компьютера, изучения анатомической структуры;
- В *других областях науки и техники*: для выделения объектов на спутниковых снимках, распознавания лиц, в системах контроля и управления дорожным движением.

Вот пример реализации алгоритма К-средних для сегментации изображения на Python с использованием библиотеки OpenCV:

ЛИСТИНГ 4.3. Пример реализации алгоритма К-средних для сегментации изображения на Python с использованием библиотеки OpenCV

```
import cv2
import numpy as np

# Загрузка изображения
image = cv2.imread('image.jpg')

# Преобразование изображения в двумерный массив точек (пикселей)
pixel_values = image.reshape((-1, 3))

# Применение алгоритма К-средних
k = 3 # количество кластеров (сегментов)
criteria = (cv2.TERM_CRITERIA_EPS + cv2.TERM_CRITERIA_MAX_ITER,
100, 0.2)
_, labels, centers = cv2.kmeans(pixel_values.astype(np.float32), k,
None, criteria, 10, cv2.KMEANS_RANDOM_CENTERS)

# Преобразование центров кластеров в целочисленный формат
centers = np.uint8(centers)

# Присвоение каждому пикселю его центра кластера
segmented_image = centers[labels.flatten()]

# Преобразование обратно в форму изображения
segmented_image = segmented_image.reshape(image.shape)
# Вывод и сохранение сегментированного изображения
cv2.imshow('Segmented Image', segmented_image)
cv2.waitKey(0)
cv2.destroyAllWindows()
cv2.imwrite('segmented_image.jpg', segmented_image)
```

В этом примере алгоритм К-средних применяется к пикселям изображения, чтобы разделить их на заданное количество кластеров (сегментов). Пиксели изображения преобразуются в двумерный массив, где каждая строка представляет один пиксель, а столбцы представляют значения цвета (каналы RGB). Затем алгоритм К-средних разбивает пиксели на кластеры, находящиеся близко друг к другу в пространстве цветов, и каждому кластеру при-

сваивается его среднее значение. Полученные центры кластеров используются для сегментации изображения, а затем отображаются и сохраняются сегментированные изображения.

Для **сегментации изображений** используются различные архитектуры нейронных сетей, включая **FCN** (Fully Convolutional Network), **U-Net** и **Mask R-CNN**.

4.1.3. Создание изображений с помощью AI

Создание изображений с помощью AI может быть выполнено различными методами, включая генеративные модели, такие как генеративно-сопоставительные сети (GAN), автокодировщики и вариационные автокодировщики.

GAN способны генерировать новые изображения, имитируя структуру и стиль обучающего набора данных.

Вот пример создания изображений с помощью генеративно-сопоставительной сети (GAN) на языке Python с использованием библиотеки TensorFlow:

ЛИСТИНГ 4.4. Пример создания изображений с помощью генеративно-сопоставительной сети (GAN) на языке Python с использованием библиотеки *TensorFlow*

```
import tensorflow as tf
from tensorflow.keras import layers, models

# Определение генератора
def build_generator(latent_dim):
    model = models.Sequential([
        layers.Dense(128 * 7 * 7, input_dim=latent_dim),
        layers.LeakyReLU(alpha=0.2),
        layers.Reshape((7, 7, 128)),
```

```

        layers.Conv2DTranspose(128, (4, 4), strides=(2, 2),
padding='same'),
        layers.LeakyReLU(alpha=0.2),
        layers.Conv2DTranspose(128, (4, 4), strides=(2, 2),
padding='same'),
        layers.LeakyReLU(alpha=0.2),
        layers.Conv2D(1, (7, 7), activation='sigmoid',
padding='same')
    ])
    return model

# Определение дискриминатора
def build_discriminator(input_shape):
    model = models.Sequential([
        layers.Conv2D(64, (3, 3), strides=(2, 2), padding='same',
input_shape=input_shape),
        layers.LeakyReLU(alpha=0.2),
        layers.Dropout(0.4),
        layers.Conv2D(128, (3, 3), strides=(2, 2), padding='same'),
        layers.LeakyReLU(alpha=0.2),
        layers.Dropout(0.4),
        layers.Flatten(),
        layers.Dense(1, activation='sigmoid')
    ])
    return model

# Определение размерности скрытого пространства
latent_dim = 100

# Сборка и компиляция дискриминатора
discriminator = build_discriminator((28, 28, 1))
discriminator.compile(loss='binary_crossentropy', optimizer='adam',
metrics=['accuracy'])

# Сборка генератора
generator = build_generator(latent_dim)

# Определение входа для генератора
z = layers.Input(shape=(latent_dim,))
generated_image = generator(z)

# Определение для обучения только генератора
discriminator.trainable = False

# Поддача сгенерированных изображений на вход дискриминатора
validity = discriminator(generated_image)

# Сборка и компиляция комбинированной модели GAN

```

```
gan = models.Model(z, validity)
gan.compile(loss='binary_crossentropy', optimizer='adam')

# Обучение GAN
# (в этом примере кода обучение будет зависеть от вашего набора
данных и конкретных параметров)
```

Этот код создает GAN с простым генератором и дискриминатором для создания изображений размером 28×28 пикселей. Обратите внимание, что обучение GAN требует тщательной настройки и адаптации к конкретным наборам данных и задачам.

Автокодировщики могут создавать изображения, восстанавливая их из скрытых представлений, изученных во время обучения на обучающем наборе данных.

Вот пример создания изображения с помощью автокодировщика на языке Python с использованием библиотеки TensorFlow:

ЛИСТИНГ 4.5. Пример создания изображения с помощью автокодировщика на языке Python с использованием библиотеки *TensorFlow*

```
import tensorflow as tf
from tensorflow.keras import layers, models

# Определение автокодировщика
def build_autoencoder(input_shape, latent_dim):
    # Энкодер
    encoder_inputs = layers.Input(shape=input_shape)
    x = layers.Conv2D(16, (3, 3), activation='relu', padding='same')(encoder_inputs)
    x = layers.MaxPooling2D((2, 2), padding='same')(x)
    x = layers.Conv2D(8, (3, 3), activation='relu', padding='same')(x)
    x = layers.MaxPooling2D((2, 2), padding='same')(x)
    x = layers.Conv2D(8, (3, 3), activation='relu', padding='same')(x)
    encoded = layers.MaxPooling2D((2, 2), padding='same')(x)

    # Декодер
```

```

x = layers.Conv2D(8, (3, 3), activation='relu', padding='same')
(encoded)
x = layers.UpSampling2D((2, 2))(x)
x = layers.Conv2D(8, (3, 3), activation='relu', padding='same')(x)
x = layers.UpSampling2D((2, 2))(x)
x = layers.Conv2D(16, (3, 3), activation='relu')(x)
x = layers.UpSampling2D((2, 2))(x)
decoded = layers.Conv2D(1, (3, 3), activation='sigmoid',
padding='same')(x)

# Модели автокодировщика
encoder = models.Model(encoder_inputs, encoded, name='encoder')
autoencoder = models.Model(encoder_inputs, decoded,
name='autoencoder')
return autoencoder, encoder

# Размерность входных изображений и размерность скрытого представления
input_shape = (28, 28, 1)
latent_dim = 32

# Сборка автокодировщика
autoencoder, encoder = build_autoencoder(input_shape, latent_dim)

# Компиляция автокодировщика
autoencoder.compile(optimizer='adam', loss='binary_crossentropy')

# Обучение автокодировщика
# (в этом примере кода обучение будет зависеть от вашего набора данных
и конкретных параметров)

```

Этот код создает простой автокодировщик для создания изображений размером 28×28 пикселей. Энкодер преобразует входные изображения в скрытое представление, а декодер восстанавливает изображения обратно из скрытого представления.

4.1.4. Создание видео с помощью AI

Создание видео с использованием AI включает в себя генерацию последовательности изображений, которые могут быть объединены в видео.

Этот процесс может быть выполнен путем **применения методов генерации изображений** к последовательности кадров или использования алгоритмов для генерации движения и динамики на основе обучающих данных.

Вот пример создания видео, включающего генерацию изображений для последовательности кадров на языке Python с использованием библиотеки OpenCV:

ЛИСТИНГ 4.6. Пример создания видео, включающего генерацию изображений для последовательности кадров на языке Python с использованием библиотеки *OpenCV*

```
import cv2
import numpy as np

# Функция для генерации изображения
def generate_image(width, height):
    # Ваш код генерации изображения
    # Например, создание случайного шума или рисование каких-либо
    # объектов
    image = np.random.randint(0, 256, (height, width, 3), dtype=np.
uint8)
    return image

# Параметры видео
width = 640
height = 480
fps = 24
duration_sec = 10

# Создание объекта VideoWriter
video_writer = cv2.VideoWriter('generated_video.mp4', cv2.
VideoWriter_fourcc(*'mp4v'), fps, (width, height))

# Генерация кадров и запись в видео
num_frames = fps * duration_sec
for i in range(num_frames):
    # Генерация изображения для текущего кадра
    frame = generate_image(width, height)

    # Запись кадра в видео
```



```

video_writer.write(frame)

# Вывод текущего номера кадра
print(f'Frame {i + 1}/{num_frames} generated')

# Закрытие объекта VideoWriter
video_writer.release()

print('Video generation complete.')

```

Этот код создает видео с длительностью 10 секунд, имеющее разрешение 640×480 пикселей и частотой кадров 24 кадра в секунду.

Каждый кадр генерируется с использованием функции `generate_image()`, которая может быть заменена на вашу функцию генерации изображений.

Для создания видео с использованием алгоритмов для генерации движения и динамики на основе обучающих данных мы можем воспользоваться генеративно-сопоставительными сетями (GAN) или вариационными автокодировщиками (VAE) для генерации новых кадров, а также использовать физические модели для моделирования движения и динамики объектов в видео.

Приведу пример использования генеративно-сопоставительных сетей для генерации новых кадров на основе обучающих данных:

ЛИСТИНГ 4.7. Пример использования генеративно-сопоставительных сетей для генерации новых кадров на основе обучающих данных

```

import numpy as np
import tensorflow as tf
from tensorflow.keras import layers, models

# Функция для создания генератора GAN
def build_generator(latent_dim, output_shape):
    model = models.Sequential([
        layers.Dense(128, input_dim=latent_dim),

```

```

        layers.LeakyReLU(alpha=0.2),
        layers.Dense(256),
        layers.LeakyReLU(alpha=0.2),
        layers.Dense(np.prod(output_shape), activation='tanh'),
        layers.Reshape(output_shape)
    ])
    return model

# Гиперпараметры
latent_dim = 100 # Размерность скрытого пространства
image_shape = (64, 64, 3) # Размеры изображений

# Создание генератора
generator = build_generator(latent_dim, image_shape)

# Генерация новых кадров
num_frames = 100
generated_frames = []
for _ in range(num_frames):
    # Генерация случайного вектора скрытого представления
    latent_vector = np.random.normal(size=(1, latent_dim))

    # Генерация изображения с помощью генератора GAN
    generated_frame = generator.predict(latent_vector)

    # Добавление сгенерированного кадра в список
    generated_frames.append(generated_frame)

# Преобразование списка кадров в видео
output_video_path = 'generated_video.mp4'
fourcc = cv2.VideoWriter_fourcc(*'mp4v')
fps = 24
width, height = image_shape[1], image_shape[0]
video_writer = cv2.VideoWriter(output_video_path, fourcc, fps,
                               (width, height))

for frame in generated_frames:
    frame = (frame * 255).astype(np.uint8) # Преобразование
значений пикселей к диапазону [0, 255]
    frame = cv2.cvtColor(frame, cv2.COLOR_RGB2BGR) # Конвертация
из RGB в формат OpenCV
    video_writer.write(frame)

# Закрытие видео-писателя
video_writer.release()

print(f'Video saved as {output_video_path}')

```

В этом примере мы создаем генератор GAN для генерации кадров на основе случайного вектора скрытого представления. Затем мы генерируем несколько кадров и сохраняем их в видеофайл.

Эти техники и методы демонстрируют возможности и перспективы использования искусственного интеллекта в области обработки изображений и видео. Они находят широкое применение в различных сферах, включая компьютерное зрение, медицинскую диагностику, автоматизацию производства, развлекательную индустрию и другие.

4.1.5. Справочный материал по разделу "Практическое применение и ссылки на графические нейросети" с кратким описанием возможностей и примерами генераций изображений

Графические нейросети

Графические нейронные сети, также известные как генеративно-состязательные сети (GANs) и их вариации имеют уникальные возможности для применения:

- **Генерация изображений и видео:** главная задача графических нейронных сетей — создание новых данных, таких как изображения и видео, на основе обучающих данных. Это может быть использовано для создания фотореалистичных изображений, анимаций, ретуши и многого другого.
- **Синтез данных:** GANs могут использоваться для синтеза данных в различных областях, таких как медицина, графика, дизайн и другие, помогая создавать новые изображения и видео, которые могут быть использованы для обучения моделей и создания нового контента.
- **Улучшение качества изображений:** некоторые архитектуры GANs могут использоваться для улучшения качества изображений, увеличения

разрешения, удаления шумов или артефактов, улучшения цветопередачи и других аспектов изображений.

- **Генерация контента:** GANs могут генерировать контент, который не существует в реальности, например фантастические сцены, изображения лиц, которых нет в базе данных, и так далее.
- **Преобразование стилей:** некоторые вариации GANs могут изменять стиль изображений, перенося его с одного изображения на другое. Это может быть использовано для переноса стилей рисовки, текстур или эффектов.

Эти возможности делают графические нейронные сети мощным инструментом для создания и обработки изображений и видео в различных областях применения. Посмотрим, какими конкретно "способностями" обладают созданные гением ученых и программистов нейросети. Стоит обратить внимание на то, что приведенные ниже ссылки на графические нейросети могут изменяться, также ежедневно появляются новые ресурсы данного типа.

Для генерации изображения, обработки фотографии в нейросети необходимо произвести следующие действия:

- зайти по ссылке;
- зарегистрироваться или воспользоваться интерфейсом без регистрации;
- используя интерфейс нейросети, сделать соответствующий запрос на генерацию. Почти все графические нейросети англоязычные. Те, кто не знает английский язык, могут воспользоваться любым удобным переводчиком.

Стоит отметить, что изображения можно создавать как с нуля, так и на основе уже сгенерированных другими пользователями изображений. Имеются разнообразные стили изображений.

Платные версии обладают гораздо большим набором функций. Некоторые графические нейросети предоставляют ограниченные бесплатные ежедневные генерации.

Некоторые работают только на платной основе.






Рис. 4.8. Представление нейросети на фоне галактики. Нейросеть Leonardo



Список графических нейросетей:




Скриншот нейросети	Ссылка на нейросеть	Краткое описание нейросети
	https://picfinder.ai/	Picfinder AI генерирует отличные изображения на базе искусственного интеллекта
	https://www.switchlight.beeble.ai/#/	Вполне возможно добиться идеальной картинки с помощью SwitchLight



	https://clipdrop.co/stable-diffusion	В Stable Diffusion XL имеется бесплатный план, который позволяет создать изображения с водяным знаком
	https://generated.photos/anonymizer	В GP/Anonymizer можно загрузить фото или выбрать похожее, созданное AI
	https://hey-photo.com/	В Heyphoto можно менять направление взгляда, форму носа, макияж, состояние кожи, возраст, эмоции и другие параметры лица
	https://bluewillow.ai	Bluewillow: от логотипов и иероглифов до цифровых иллюстраций и фотографий — просто опишите изображение, которое вы хотите, и наш инструмент для создания изображений с искусственным интеллектом создаст идеальную графику для вашего проекта. Это можно попробовать бесплатно

	https://www.ostagram.me/lenta?locale=en	Ostagram поможет приукрасить страничку пользователей в социальных сетях или просто развлечься с друзьями
	https://deepdreamgenerator.com/	Deep Dream предоставляет возможность воплотить в изображении любую вашу фантазию
	https://app.photoroom.com/create	PhotoRoom. Прекрасный редактор фото для самых разных нужд
	https://www.patterned.ai/	PatternedAI. Создавайте уникальные узоры для вашего изделия с помощью искусственного интеллекта! Ищите и создавайте тысячи бесплатных узоров для любой поверхности с помощью нашего простого инструмента с искусственным интеллектом!


GLIGEN: Open-Set Grounded Text-to-Image Generation Yuheng Li, Haotian Liu, Qingyang Wu, Fangzhou Mu, Jianwei Yang, Jianfeng Gao, Chunyuan Li*, Yong Jae Lee* ► University of Wisconsin-Madison; ► Columbia University; ► Microsoft *Equal Advising GitHub Hugging Face arXiv Paper	https://gligen.github.io	GLIGen. Сгенерирует любой текст в изображение. Можно задать расположение объектов с помощью предварительного наброска
 NEURONCA Главная » Картинки Neural-Photo-Editor Бесплатно Без VPN	https://neuronca.ru/neural-photo-editor	Neural-Photo-Editor — это профессиональный онлайн-редактор изображений на базе ИИ от Anthropic. Загрузите фотографию — и инструменты на основе нейросетей позволят мгновенно удалить фон, устранить дефекты, применить художественные фильтры одним кликом
 English ▼ Pricing Pro The Fastest Way To Edit Photos Finally, an AI-powered photo editing solution for i-ghenon Classic that learns your personal style and saves you time. Download and get 1,000 free AI edits.	https://imagen-ai.com/?v=1c	Imagen. Самый быстрый способ редактирования фотографий. Наконец, решение для редактирования фотографий на базе искусственного интеллекта для Lightroom. Классика, которая учит вашему индивидуальному стилю и экономит ваше время. Кредитная карта не требуется



	https://prisma-ai.com/lensa	Lensa — это универсальное приложение для редактирования изображений, которое выводит ваши фотографии на новый уровень
	https://dmitrvulyanov.github.io/deep_image_prior	Deep Image Prior. Глубокие нейронные сети восстанавливают изображения. Решают проблемы с изображениями
	https://deoldify.ai/	DeOldify — это современный способ раскрашивания черно-белых изображений. Вы можете попробовать его прямо сейчас, посетив бесплатный Google Colab notebook для просмотра фотографий или видео. Записные книжки с открытым исходным кодом доступны всем
	https://phillipi.github.io/pix2pix/	pix2pix позволяет создавать преобразование изображений с обучением и без учителя


	https://replicate.com/lambda/text-to-pokemon	text-to-pokemon. Введите текстовое задание и создайте своего собственного персонажа-покемона
	https://www.fantoons.xyz/	Fantoons. Создавайте свои собственные фан-комиксы
	https://github.com/microsoft/TaskMatrix	Visual-chatgpt. Возможность работать с изображениями прямо в чате
	https://www.watermarkremover.io/ru	Watermark Remover. С помощью WatermarkRemover.io вы можете плавно избавиться от полупрозрачных водяных знаков с изображений всего за несколько секунд
	https://www.erase.bg/ru	Erase.bg — удаление фона с изображений БЕСПЛАТНО. Почувствуйте точное удаление фона. Зарегистрируйтесь сегодня, чтобы получить первые 3 кредита бесплатно!

 Convert Your Images Online for Free You can easily convert your image files in the desired format without any quality loss.	https://www.convertfiles.ai/	ConvertFiles.ai — конвертируйте свои изображения онлайн бесплатно без потери качества
 GET IT ON Google Play Download on the App Store Создайте чат-бот для сайта за	https://www.upscale.media/ru	Upscale.media — улучшайте изображения с использованием искусственного интеллекта бесплатно
 GET IT ON Google Play Download on the App Store Уменьшите размер ваших изображений БЕСПЛАТНО	https://www.shrink.media/ru	Shrink.media — уменьшите размер ваших изображений бесплатно
Click here to try. 1-click AI any IMGCREATOR Products Community History Resources AI Image Text to image, image to image	https://imgcreator.zmo.ai/	Imgcreator — генератор изображений с искусственным интеллектом. Преобразование текста в изображение, с картинки на картинку и смена фона
PicWish Features Use Cases Download APP For Developers (APIs) AI Face Swap Tool AI-Powered Creative	https://picwish.com/	Pic Wish — платформа для редактирования фотографий с использованием искусственного интеллекта


	https://www.vizcom.ai/	Vizcom — кратчайший путь от воображения к визуализации. Воплотите свои дизайнерские идеи в жизнь
 Zarla Free logo maker Create a Free Logo with Zarla	https://www.zarla.com/logo-maker/	Zarla — создайте бесплатный логотип с помощью Zarla. Красивый дизайн логотипа стал проще простого
	https://fusionbrain.ai/	Kandinsky 2.1. Идеи в образы. Создавайте изображения и видео за секунды с помощью текстовых описаний. ИИ от Сбера
 AutoDraw Fast drawing for everyone.	https://www.autodraw.com/	AutoDraw. Универсальный инструмент для рисования. Бесплатно. Работает на всех гаджетах
 BENZIN neural network	https://benzin.io/ru/	Benzin — удаляет фон с изображений. Наша нейросеть очень быстро обработает огромное количество ваших фотографий

	https://artist.croissanstudio.ru/	НейроХудожник — генерирует графику на языке дизайна. Не придумывайте сложные текстовые запросы, описывайте графику в визуальном интерфейсе
	https://dream.ai/create	Dream. Создавайте изображения на основании своих идей и выбора художественного стиля
	https://picsart.com/photo-editor	Picsart — бесплатный онлайн-редактор фотографий, созданный для творческих людей. Здесь есть все необходимые инструменты
	https://www.restorephotos.io/	restorePhotos — восстановление старых фотографий с помощью искусственного интеллекта. У вас есть старые и размытые фотографии лиц? Позвольте нашему искусственному интеллекту восстановить их, чтобы воспоминания остались в памяти. 100% бесплатно – восстановите свои фотографии сегодня

	https://palette.fm/	Palette. Смотрите на свои фотографии в реалистичных цветах. Загрузите свою фотографию, выберите свой уникальный фильтр и наблюдайте, как ваш момент преобразуется за счет ярких, реалистичных цветов за считанные секунды
	https://openai.com/dall-e-2	DALL-E 2 — это система искусственного интеллекта, которая может создавать реалистичные изображения и произведения искусства на основе описания на естественном языке
	https://flim.ai/	Flim поможет вам найти идеальное изображение для выражения ваших идей, чтобы вы могли более эффективно осуществлять свой творческий процесс
	https://jpghd.com/	jpgHD — увеличение изображения без потерь, (поддерживает старые поцарапанные фотографии). Увеличивает разрешение, раскрашивает черно-белые фото

		jpgRM — волшебная очистка изображения AI. Используйте самый передовой искусственный интеллект 2024 AI, чтобы стереть любые нежелательные части ваших изображений и заполнить фоновый контент
		Stable Diffusion Online — это скрытая модель преобразования текста в изображение, которая позволяет создавать фотореалистичные изображения при любом вводе текста, обеспечивает автономную свободу для создания невероятных изображений и позволяет миллиардам людей создавать потрясающие произведения искусства за считанные секунды. Создавайте красивые произведения искусства с помощью Stable Diffusion Online бесплатно
		Stablecog — создавайте удивительные произведения искусства за считанные секунды с помощью искусственного интеллекта

	https://github.com/CompVis/stable-diffusion	Stable Diffusion — генерирует изображения по текстовому описанию
	https://github.com/EmpireMediaScience/A1111-Web-UI-Installer	Stable Diffusion web UI — интерфейс браузера на основе библиотеки Gradio для Stable Diffusion. Включает закрашивание, матрицу подсказок, масштабирование, текстовую инверсию, пакетную генерацию, рандомизаторы, опросник CLIP
	https://www.midjourney.com/app/	MidJourney — Discord-бот для создания изображений из текста
	https://deform.art/	Deform Stable Diffusion — это инструмент для создания анимационных видеороликов со Stable Diffusion. Вам нужно только предоставить текстовые подсказки и настройки движения камеры

	https://caricaturer.io/	Caricaturer.io — это онлайн-редактор фотографий-карикатур. Способен создать более 60 фотографий-карикатур на основе портретов с помощью искусственного интеллекта и технологии глубокого обучения
	https://generated.photos/	Generated Photos — создает фотографии полностью с помощью искусственного интеллекта. Содержит галерею высококачественных разнообразных фотографий, а также позволяет создавать уникальные модели по собственным параметрам в режиме реального времени
	https://leonardo.ai/	Leonardo Ai — создает визуальные ресурсы производственного качества с беспрецедентным качеством, скоростью и соответствием стилю. Предоставляет ограниченное число бесплатных генераций

Приведем пример генерации кота-самурая в нейросети Leonardo:



Рис. 4.9. Кот-самурай

Как можно заметить при внимательном рассмотрении сгенерированной картинки, у кота-самурая 6 лап. Это можно исправить. Для этого во многих графических нейросетях существует "Негативный промт".

Чем детальнее задание, которое вы дадите нейросети, тем лучше оно его исполняет, хотя и это не всегда "работает". Нейросеть учится в процессе общения с вами. Пока еще нейросети не очень хорошо справляются с изображениями человеческих лиц, количеством пальцев на руке, изображениями ног. Все это можно исправлять в процессе и получать на выходе хороший результат. Также нейросеть не всегда "понимает" ваше задание.

Приведем пример подобного "непонимания" или "сомнения" нейросети при генерации изображения по запросу.

Запрос нейросети Leonardo Ai: студенты сидят за столом и пишут программу на языке программирования Python.

Результаты нескольких генераций по запросу с выдачей результата с ошибками (в основном) плюс одно условно верное изображение:



Рис. 4.10. Девушка-студентка и вылезающий из-за экрана ноутбука питон



Рис. 4.11. Девушка-студентка и сидящий за ее спиной питон-ящер



Рис. 4.12. Студенты работают за ноутбуком



Рис. 4.13. Девушка-студентка работает за ноутбуком. Рядом с ней сидит ящер



Рис. 4.14. Девушка-студентка работает за ноутбуком



Рис. 4.15. Ящер работает за ноутбуком

Из вышеприведенных сгенерированных изображений мы видим, что нейросеть не совсем верно поняла задание. Нейросеть сформировала одновременно несколько вариантов картинок. Язык программирования Python превратился в питона и ящера. И все же имеется картинка, примерно отражающая именно то, что мы имели в виду, формируя этот запрос. Стоит также обратить внимание на глаза и пальцы людей. Они не везде выглядят хорошо. А питон-ящер выглядит очень реалистично.

Но методом проб и ошибок возможно добиться идеального изображения.

Некоторые нейросети позволяют из сгенерированных картинок создать фильм или мультфильм. Это еще более раздвигает границы человеческого творчества. Теперь каждый может создать небольшой фильм или мультфильм по своему желанию.



Так же практически во всех графических нейросетях возможно создавать изображения на основе уже существующих моделей и в разных стилях. Вот пример сгенерированного изображения гориллы в образе доктора, стиль киберпанк:






Рис. 4.16. Пример генерации изображения гориллы в образе доктора, стиль киберпанк, Леонардо ИИ


Рассмотрим нейросети, с помощью которых можно создавать видео.

Видеонейросети

Скриншот нейросети	Ссылка на нейросеть	Краткое описание нейросети
	https://kaiber.ai/	Kaiber. Откройте в себе художника. Превращайте текст, видео, фотографии и музыку в потрясающие видеоролики с помощью нашего продвинутого движка искусственного интеллекта
	https://magicvideo.github.io/index.html	MagicVideo. Эффективная генерация видео с использованием моделей скрытой диффузии
	https://runwayml.com/	RunwayML. Развитие креативности с помощью искусственного интеллекта. Формирует новую эру искусства, развлечений и креативности человека

	https://www.synthesia.io/	Synthesia. Преобразуйте текст в видео за считанные минуты. Создавайте видеоролики студийного качества с аватарами и озвучкой с использованием искусственного интеллекта на более чем 130 языках
	https://vrew.vovagerx.com/en/	Vrew. Создавайте видеоролики, готовые к публикации. Вместе с Vrew сделайте шаг в будущее создания видео, где каждая идея становится шедевром
	https://bigmp4.com/	bigMP4. Увеличение масштаба видео в формате HD без потерь, интеллектуальное заполнение кадра для получения шелковисто-гладкого и реалистичного изображения
	https://replicate.com/nateraw/stable-diffusion-videos	Stable-diffusion-videos. Создавайте видео, интерполируя скрытое пространство Stable Diffusion

	https://replicate.com/andreasjansson/stable-diffusion-animation	Stable-diffusion-animation. Анимация Stable Diffusion путем интерполяции между двумя подсказками
	https://www.move.ai/	Move.ai. Продукты Move AI для захвата движения без маркировки позволяют легко снимать и создавать 3D-анимацию
	https://www.topazlabs.com/topaz-video-ai	Topaz Video AI. Улучшите качество отснятого материала. Нам доверяют крупнейшие киностудии и профессионалы в области креатива во всем мире
	https://colourlab.ai/	Colourlab AI. Программное обеспечение для цветокоррекции на основе искусственного интеллекта, которое заслужило доверие голливудских создателей контента
	https://fliki.ai/	Fliki. Воплотите свои идеи в потрясающие видеоролики с помощью нашего генератора видео с искусственным интеллектом. Широкий спектр функций, основанных на ИИ

	https://www.augxlabs.com/	Aug X Labs. Превратите свои слова в видео. Создавайте профессиональные видеоролики за считанные минуты
	https://maimovie.com/	Maimovie. Без особых усилий находите фильмы и телешоу, соответствующие вашим предпочтениям
	https://app.heygen.com...=moviola	Movio. Создавайте видеоролики для маркетинга или обучения за три простых шага
	https://www.deepbrain.io/	Deepbrain. Создавайте видео из текста. Масштабируйте свои видеопроекты с помощью преобразования текста в видео на базе искусственного интеллекта
	https://www.opus.pro/	Opus Clip. Инструмент для создания видео с использованием искусственного интеллекта, который превращает длинные видео в короткие одним щелчком мыши

This experience is
not supported on
your browser/device.

[https://
thedreamkeeper.co/](https://thedreamkeeper.co/)

The Dreamkeeper.
Опишите свой сон,
и The Dreamkeeper
создаст короткий
видеоролик

4.2. Распознавание голоса, озвучка, перевод на другой язык и иные способы

Распознавание голоса, озвучка, перевод на другие языки и другие способы обработки аудио с помощью искусственного интеллекта представляют собой важные и широко применяемые технологии.

Вот некоторые из них.

4.2.1. Распознавание голоса

Распознавание голоса — это процесс преобразования аудиосигнала голоса человека в текст. Для распознавания голоса используются алгоритмы машинного обучения, включая рекуррентные нейронные сети (RNN) и сверточные нейронные сети (CNN), а также технологии обработки естественного языка (NLP).

Вот пример на Python, использующий библиотеку SpeechRecognition для преобразования аудио в текст:

ЛИСТИНГ 4.17. Пример на Python, использующий библиотеку *SpeechRecognition* для преобразования аудио в текст

```
import speech_recognition as sr

# Создание объекта Recognizer
recognizer = sr.Recognizer()

# Загрузка аудиофайла
audio_file = "audio.wav"
with sr.AudioFile(audio_file) as source:
    # Запись аудио из файла
    audio_data = recognizer.record(source)

    # Преобразование аудио в текст с использованием Google Web
    # Speech API
    text = recognizer.recognize_google(audio_data, language="ru-RU")

# Вывод результата
print("Текст из аудио:", text)
```

Этот код загружает аудиофайл `audio.wav`, преобразует его в текст с помощью Google Web Speech API и выводит результат.

4.2.2. Озвучка

Озвучка — это процесс преобразования текста в речь, где компьютер генерирует аудиосигнал, соответствующий заданному тексту.

Системы озвучки обычно используют генеративные модели, такие как WaveNet и Tacotron, которые обучаются на больших наборах данных голосов и текста.

Вот пример на Python, использующий библиотеку gTTS (Google Text-to-Speech) для преобразования текста в речь:

ЛИСТИНГ 4.18. Пример на Python, использующий библиотеку gTTS (Google Text-to-Speech) для преобразования текста в речь

```
from gtts import gTTS
import os

# Текст для преобразования
text = "Привет! Я голосовой помощник."

# Создание объекта gTTS с указанием языка (русский) и скорости речи
tts = gTTS(text=text, lang='ru')

# Сохранение аудио в файл
tts.save("output.mp3")

# Воспроизведение аудиофайла
os.system("start output.mp3")
```

Этот код создает голосовую запись на основе текста, указанного в переменной `text`, на русском языке. Аудио сохраняется в файл `output.mp3`, который затем воспроизводится с помощью операционной системы.

4.2.3. Перевод на другие языки

Перевод аудио на другие языки — это процесс преобразования аудиосигнала из одного языка в другой. Для этого используются системы автоматического распознавания речи (ASR) для преобразования аудио в текст на исходном языке, а затем системы машинного перевода для перевода текста на целевой язык.

Вот пример на Python, который использует библиотеку `SpeechRecognition` для распознавания речи и библиотеку `googletrans` для машинного перевода текста:

ЛИСТИНГ 4.19. Пример на Python, который использует библиотеку `SpeechRecognition` для распознавания речи и библиотеку `Googletrans` для машинного перевода текста

```
import speech_recognition as sr
from googletrans import Translator

# Создание объектов Recognizer и Translator
recognizer = sr.Recognizer()
translator = Translator()

# Загрузка аудиофайла
audio_file = "audio.wav"
with sr.AudioFile(audio_file) as source:
    # Запись аудио из файла
    audio_data = recognizer.record(source)

    # Преобразование аудио в текст с использованием Google Web
    # Speech API
    text = recognizer.recognize_google(audio_data, language="ru-RU")

    # Перевод текста на целевой язык
    translated_text = translator.translate(text, dest='en').text

# Вывод результата
print("Текст на исходном языке": text)
print("Переведенный текст:", translated_text)
```

4.2.4. Анализ аудиосигналов

Анализ аудиосигналов включает в себя выявление различных акустических и аудиофонетических характеристик с целью распознавания речи, идентификации аудиофайлов или обнаружения аномалий.

Для анализа аудиосигналов могут использоваться методы машинного обучения, такие как глубокие нейронные сети и алгоритмы временных рядов.

Вот пример на Python, использующий библиотеку Librosa для анализа аудиосигнала и извлечения различных характеристик, таких как мел-кепстральные коэффициенты (MFCC), хроматические признаки и темп:

ЛИСТИНГ 4.20. Пример на Python, использующий библиотеку Librosa для анализа аудиосигнала и извлечения различных характеристик, таких как мел-кепстральные коэффициенты (MFCC), хроматические признаки и темп

```
import librosa
import numpy as np

# Загрузка аудиофайла
audio_file = "audio.wav"
audio_data, sample_rate = librosa.load(audio_file)

# Извлечение мел-кепстральных коэффициентов (MFCC)
mfccs = librosa.feature.mfcc(y=audio_data, sr=sample_rate, n_mfcc=13)

# Извлечение хроматических признаков
chroma = librosa.feature.chroma_stft(y=audio_data, sr=sample_rate)

# Извлечение темпа
tempo = librosa.beat.tempo(y=audio_data, sr=sample_rate)

# Вывод результатов
print("MFCC shape:", mfccs.shape)
print("Chroma shape:", chroma.shape)
print("Tempo:", tempo)
```

Этот код загружает аудиофайл audio.wav, использует библиотеку Librosa для извлечения мел-кепстральных коэффициентов (MFCC), хроматических признаков и темпа аудиосигнала.

Эти характеристики могут быть использованы для распознавания речи, идентификации аудиофайлов или обнаружения аномалий, в зависимости от конкретной задачи.

4.2.5. Музыкальные генеративные модели

Музыкальные генеративные модели, такие как Magenta от Google, могут генерировать новую музыку на основе обучающих данных. Эти модели могут создавать музыкальные композиции в различных стилях и жанрах, а также имитировать стиль конкретного композитора или исполнителя.

Эти технологии обработки аудио с помощью искусственного интеллекта играют важную роль в различных областях, включая образование, медицину, развлечения, мобильные приложения и многое другое. Они делают аудиоинформацию доступной, понятной и удобной для использования в различных контекстах.

Вот пример на Python, который использует библиотеку Magenta для создания музыкальной генеративной модели с помощью глубокого обучения:

ЛИСТИНГ 4.21. Пример на Python, который использует библиотеку *Magenta* для создания музыкальной генеративной модели с помощью глубокого обучения

```
import magenta.music as mm
import magenta.models.music_vae as mvae
import magenta.music.sequence_generator as sg
from magenta.models.music_vae import TrainedModel
```



```
# Загрузка предобученной модели
model_name = "cat-mel_2bar_big"
model_config = mvae.configs.CONFIG_MAP[model_name]
model_hparams = mvae.trained_model.get_default_hparams(model_name)
model = TrainedModel(model_name, model_config, model_hparams)

# Создание среды обучения
mm.notebook_utils.download_bundle("cat-mel_2bar_big", "bundles")
bundle = mm.sequence_generator_bundle.read_bundle_file("bundles/cat-
mel_2bar_big.mag")
generator_map = mm.generator_pb2.GeneratorDetails(id='default',
description='')
generator = sg.BaseSequenceGenerator(model, generator_map)

# Генерация новой музыки
num_steps = 128 # Длина новой мелодии в шагах
temperature = 0.5 # Параметр для контроля степени случайности генерации
generated_sequence = generator.generate(num_steps=num_steps,
temperature=temperature)

# Сохранение сгенерированной музыки в MIDI файл
mm.sequence_proto_to_midi_file(generated_sequence, 'generated_music.mid')
```




Этот код использует библиотеку Magenta для загрузки предобученной модели (в данном случае модели cat-mel_2bar_big).





Затем модель используется для генерации новой музыки заданной длины (num_steps) с учетом параметра **temperature**, который контролирует степень случайности генерации.

Результат сохраняется в MIDI-файл.

4.2.6. Справочный материал по разделу "Распознавание голоса, озвучка, перевод на другой язык и иные способы"

Аудионейросети

Скриншот нейросети	Ссылка на нейросеть	Краткое описание нейросети
	https://www.riffusion.com/	Riffusion. Создает любую музыку, какую только пожелаете. Мы создаем что-то новое
	https://fakeyou.com/	FakeYou. AI-музыка, преобразование текста в речь и голос в голос. Используйте технологию дипфейков FakeYou для создания аудио или видео ваших любимых персонажей, говорящих все, что вы хотите
	https://cybervoice.io/ru/	SteosVoice —сервис для озвучки текста. Открывает новые горизонты для творчества и создания контента
	https://www.naturalreaders.com/	Natural Reader позволяет преобразовать текст в речь на базе искусственного интеллекта

	https://soundraw.io/	Soundraw —создает треки с использованием искусственного интеллекта для фоновой музыки. Попробуйте бесплатно
	https://verbatik.com/	Verbatik — создает голоса с помощью искусственного интеллекта которые звучат в точности как человеческие при преобразовании текста в речь
	https://fadr.com/	Fadr. Делает ремиксы, используя музыку с искусственным интеллектом. Выберите приложение и загрузите песню
	https://vocalremover.org/	Vocal Remover. Удаляет и изолирует вокал. Отделите голос от музыки в песне бесплатно с помощью мощных алгоритмов искусственного интеллекта
	https://endel.io/	Endel. Персонализированные звуковые эффекты, которые помогут вам сосредоточиться, расслабиться и уснуть. При поддержке неврологии

	https://podcast.adobe.com/enhance16	Adobe Enhance Speech. Аудиоинструменты на базе искусственного интеллекта, которые улучшат ваш голос
---	--	--

4.3. Обработка естественного языка (Natural Language Processing, NLP)

Обработка естественного языка — это область искусственного интеллекта, которая занимается анализом, пониманием и генерацией текста на естественных языках.

Вот некоторые ключевые аспекты обработки естественного языка.

4.3.1. Анализ текста

Анализ текста включает в себя различные задачи, такие как выделение ключевых слов, именованных сущностей, а также определение тональности и эмоциональной окраски текста.

Для анализа текста используются методы машинного обучения, включая модели на основе слов (Word2Vec, GloVe), рекуррентные нейронные сети (RNN), сверточные нейронные сети (CNN) и трансформеры.

Вот пример кода на Python, который использует библиотеку `nltk` для анализа текста и модель на основе слов:

ЛИСТИНГ 4.22. Пример кода на Python, который использует библиотеку *nltk* для анализа текста и модель на основе слов

```
import nltk
from nltk.tokenize import word_tokenize
from nltk.corpus import stopwords
from collections import Counter

# Загрузка стоп-слов
nltk.download('punkt')
nltk.download('stopwords')

# Текст для анализа
text = "Вот пример текста для анализа. Мы будем использовать его для подсчета количества вхождений каждого слова."

# Токенизация текста
tokens = word_tokenize(text)

# Удаление стоп-слов
stop_words = set(stopwords.words('russian'))
filtered_tokens = [word for word in tokens if word.lower() not in stop_words]

# Подсчет количества вхождений каждого слова
word_count = Counter(filtered_tokens)

# Вывод результатов
print("Количество вхождений каждого слова:")
print(word_count)
```

Этот код сначала разбивает текст на отдельные слова (токенизация), затем удаляет стоп-слова (наиболее часто встречающиеся слова, которые обычно не несут смысловой нагрузки) и, наконец, подсчитывает количество вхождений каждого слова.

4.3.2. Классификация текста

Классификация текста — это процесс присвоения категории или метки тексту в соответствии с его содержанием.

Примеры задач классификации текста включают анализ тональности текста (позитивный, негативный, нейтральный), определение темы текста, классификацию спама и идентификацию языка.

Вот пример кода на Python, использующий библиотеку `nltk` для классификации текста по тональности, определения темы текста, классификации спама и идентификации языка:

ЛИСТИНГ 4.23. Пример кода на Python, использующий библиотеку `nltk` для классификации текста по тональности, определения темы текста, классификации спама и идентификации языка

```
import nltk
from nltk.sentiment import SentimentIntensityAnalyzer
from nltk.tokenize import word_tokenize
from nltk.corpus import stopwords
from collections import Counter
from langdetect import detect

# Загрузка стоп-слов и анализатора тональности
nltk.download('punkt')
nltk.download('stopwords')
nltk.download('vader_lexicon')

# Текст для анализа
text = "Это просто удивительное приложение! Я в восторге от его функциональности и удобства. Спасибо разработчикам!"
spam_text = "Получите бесплатный iPhone прямо сейчас! Просто введите свой email и получите его!"

# Анализ тональности
sid = SentimentIntensityAnalyzer()
sentiment_scores = sid.polarity_scores(text)
if sentiment_scores['compound'] >= 0.05:
```

```

    sentiment = "Позитивный"
elif sentiment_scores['compound'] <= -0.05:
    sentiment = "Негативный"
else:
    sentiment = "Нейтральный"
print("Тональность текста:", sentiment)

# Определение языка
language = detect(text)
print("Язык текста:", language)

# Классификация спама
spam_keywords = ["бесплатно", "акция", "скидка", "подарок"]
tokens = word_tokenize(spam_text.lower())
spam_count = sum(1 for word in tokens if word in spam_keywords)
if spam_count >= 2:
    is_spam = True
else:
    is_spam = False
print("Это спам:", is_spam)

# Определение темы текста
topic_keywords = ["приложение", "функциональность", "удобство"]
tokens = word_tokenize(text.lower())
topic_count = sum(1 for word in tokens if word in topic_keywords)
if topic_count >= 2:
    topic = "Приложения"
else:
    topic = "Общее"
print("Тема текста:", topic)

```

Этот код анализирует текст с помощью анализатора тональности, определяет язык и тему текста, а также то, относится он к спаму или нет.

4.3.3. Создание текста

Создание текста с помощью NLP может включать в себя задачи генерации текста на основе заданных параметров или контекста.

Генеративные модели, такие как **рекуррентные нейронные сети (RNN)**, **генеративно-состязательные сети (GAN)** и **трансформеры**, могут быть использованы для создания новых текстовых данных.

Вот пример кода на Python, который создает текст на основе заданных параметров или контекста:

ЛИСТИНГ 4.24. Пример кода на Python, который создает текст на основе заданных параметров или контекста

```
import random

# Список слов для генерации текста
nouns = ["кот", "собака", "дом", "автомобиль", "парк", "река"]
adjectives = ["большой", "маленький", "красивый", "старый",
              "новый", "зеленый"]
verbs = ["бежит", "прыгает", "плавает", "летит", "идет", "сидит"]
adverbs = ["быстро", "медленно", "активно", "тихо", "громко",
            "весело"]

# Генерация случайного предложения
def generate_sentence():
    sentence = f"{random.choice(adjectives)} {random.choice(nouns)} {random.choice(verbs)} {random.choice(adverbs)}."
    return sentence.capitalize()

# Генерация текста на основе заданного количества предложений
def generate_text(num_sentences):
    text = ""
    for _ in range(num_sentences):
        text += generate_sentence() + " "
    return text

# Генерация текста из 5 предложений
generated_text = generate_text(5)
print(generated_text)
```

Этот код создает текст, используя случайные слова из списка существительных, прилагательных, глаголов и наречий, а затем формирует предложения на основе этих слов.

Результат — текст, состоящий из заданного количества предложений.

4.3.4. Перевод текста

Перевод текста — это процесс перевода текста с одного языка на другой. Системы машинного перевода используют алгоритмы обработки естественного языка, такие как рекуррентные нейронные сети (RNN) и трансформеры, для автоматического перевода текста.

Вот пример кода на Python, использующий библиотеку Googletrans для перевода текста с одного языка на другой:

ЛИСТИНГ 4.25. Пример кода на Python, использующий библиотеку *Googletrans* для перевода текста с одного языка на другой

```
from googletrans import Translator

# Создание объекта переводчика
translator = Translator()

# Текст для перевода
text = "Привет, как дела?"

# Определение исходного языка текста
detected_lang = translator.detect(text).lang

# Перевод текста на английский язык
translated_text = translator.translate(text, src=detected_lang,
dest='en')

# Вывод переведенного текста
print("Переведенный текст на английский:", translated_text.text)
```

Этот код использует библиотеку Googletrans, чтобы определить язык исходного текста и перевести его на заданный язык (в данном случае на английский).







ПРИМЕЧАНИЕ. Обработка естественного языка имеет широкий спектр применений в различных областях, включая поисковые системы, чат-боты, анализ текста в социальных сетях, машинный перевод, автоматизацию клиентского обслуживания и многое другое. Эти технологии делают текстовую информацию доступной и понятной для анализа и использования в различных контекстах.

4.3.5. Справочный материал по разделу "Обработка естественного языка (Natural Language Processing, NLP)"



Текстовые нейросети



Скриншот нейросети	Ссылка на нейросеть	Краткое описание нейросети
	https://developers.sber.ru/...=2	GigaChat. Бесплатная нейросетевая модель. Отвечает на вопросы. Ведет диалог. Рисует картинки. Пишет код. Предлагает идеи. Делает рутинные задачи



	https://pdfparser.co/	PDF Parser. Повысьте свою производительность. Преобразуйте любые файлы PDF в JSON онлайн
	https://iqbid.ai/	Iqbid. Идеальный AI-помощник. Используйте искусственный интеллект, чтобы сделать творческий прорыв, увеличить конверсию или повысить продажи
	https://www.nolanai.app/	Nolan — сервисный центр киноиндустрии, помогающий вывести следующий шедевр на большие экраны. Напишет сценарий, перепишет и отформатирует текст. Также найдет и исправит грамматические ошибки
	https://fusion.tiiny.site/	FusionAI. Генерирует prompts для ChatGPT
	https://www.readtrellis.com/?ref=zHaL0r	Trellis. Чтение и обучение с помощью искусственного интеллекта. Выделите любой текст и упростите его до произвольного уровня сложности

 Create your own AI-powered	https://makemytale.com/3	Makemytale. Создайте свою собственную историю, основанную на искусственном интеллекте
 ChatGPT for Google ChatGPT response alongside search engine results. Now supports GPT4, Claude ★★★★★ Trusted by 2,000,000+ users Add to Chrome Add to Edge Add to Firefox	https://chatgpt4google.com/	ChatGPT for Google. Расширение для Chrome и Firefox. Добавляет ответы от нейросети в результаты поиска
 MyGPT by SamurAI A better UI for ChatGPT	https://mygpt.thesamurai.ai/	MyGPT. Интерфейс ChatGPT. Нужен ключ API OpenAI
 Content at Scale	https://contentatscale.ai/	Content at Scale. Создаем самый глубокий, человеческий и полезный SEO-контент на планете
 Manage jaw-droppi	https://socialbee.com/	SocialBee. Создавайте, перерабатывайте, планируйте, публикуйте, анализируйте, привлекайте к сотрудничеству и утверждайте свои публикации в социальных сетях — все это в одном месте

 Free Resume Maker Online POWERED BY AI The Easiest Way to Build the Perfect Resume Make your resume stand out with our incredibly easy-to-use Resume. Turn hours of work into minutes with AI—less typing, more applying.	https://www.resumemaker.online/	Resume Maker — самый простой способ составить идеальное резюме. Превратите часы работы в минуты с помощью искусственного интеллекта — меньше печатать, больше подавать заявки!
 AI Author : Write like Writers AI story, article, book writing 141881 Unlaid Designed for iPad ***** AI-powered Free. Offers In-App Purchases	https://apps.apple.com/us/app/ai-author-write-like-writers/id6445870532	AI Author — просто введите текст, выберите автора нужной книги из списка и позвольте приложению творить чудеса. Наши экспертные алгоритмы анализируют стиль письма, грамматику и интонацию выбранных авторов и легко применяют их к вашему тексту
ChatSonic AI & A ChatGPT Alternative Is ChatGPT down? Not anymore! Get Jasper How about trying Jasper Chat as an alternative to ChatGPT and ChatSonic AI? It has been Chat GPT is an AI chatbot created by OpenAI and released in 2022, whereas Chatsonic 	https://www.chat-sonic.com/#google_vignette	ChatSonic — расширенное приложение Chrome, похожее на ChatGPT, предназначено для экономии вашего времени и усилий при работе с Gmail, Twitter

	https://monica.im/	Monica — универсальный помощник, оснащенный самыми передовыми моделями ИИ (GPT-4, Claude 3, Gemini и другими), чтобы помочь вам общаться, искать, писать, переводить и делать многое другое. Также предоставляются инструменты для обработки изображений, видео и PDF
	https://noty.ai/	Noty.ai — записывайте, обобщайте и отслеживайте задачи с помощью искусственного интеллекта. Чтобы оставаться продуктивным, составляйте списки дел на каждой встрече с помощью искусственного интеллекта
	https://www.asterixwriter.com/features	Asterix — редактируйте свои тексты так же, как вы редактируете фотографии. Разработанный для того, чтобы избавить вас от рутинной работы по редактированию, Asterix сочетает в себе красивый текстовый редактор и передовые инструменты искусственного интеллекта

	https://openai.com/research/gpt-4	GPT-4 — ChatGPT-бот, который умеет распознавать изображения. Доступ по платной подписке либо по листу ожидания API
	https://mictoo.com/	Mictoo — поможет вам сосредоточиться на разговоре, а не на заметках. Вы можете записать или загрузить файл и получить транскрипцию в режиме реального времени. Mictoo также создает сводку собрания и действий
	https://openai.com/blog/chatgpt	ChatGPT — языковая модель, которая взаимодействует в диалоговом режиме
	https://www.notion.so/product/ai	Notion AI. Просто спросите у Notion AI. Знания, ответы, идеи. Всего в один клик
	https://mathgpt.streamlit.app/#mathgpt	MathGPT. Решает математические задачи

	https://app.copy.ai/login?from=redirect&destination=%3F	Copy.ai. Напишет статью, письмо, пост в социальные сети или блог
	https://app.jenni.ai/register?referral=e05327dd	Jenni. Напишет любой текст, перефразирует текст
	https://www.deepl.com/write	DeepL Write. Производит корректировку грамматических и пунктуационных ошибок, подбор наиболее точных формулировок и изменение тона текста
	https://www.aipoemgenerator.org/	AI Poem Generator. Отправьте ИИ-модели запрос на ввод, чтобы она рассказала, о чем вы хотели бы, чтобы было стихотворение, и наш создатель стихотворений мгновенно напишет вам красивое рифмованное стихотворение на английском языке
	https://www.gptforslides.app/	GPT for Slides. Создавайте слайды презентаций с помощью искусственного интеллекта за считанные секунды

	https://type.ai/	Type AI — это первый редактор документов с искусственным интеллектом, который помогает любому пользователю создавать контент с высокой отдачей
	https://explainlikeimfive.io/	Explain Like I'm Five. Объясняет сложные темы так, чтобы их понял даже ребенок. Таким образом, вы всегда сможете легко найти нужные ответы
	https://glasp.co/youtube-summary	YouTube Summary. Обзор YouTube с помощью ChatGPT и Claude. Получите обзор видеороликов на YouTube. Учитесь лучше с помощью ChatGPT и Claude
	https://chord.pub/	Chord. Добейтесь консенсуса в Интернете по любой теме

4.4. Медицина и здравоохранение. Диагностика заболеваний. Разработка лекарств и иные сферы применения

Искусственный интеллект (ИИ) играет значительную роль в медицине и здравоохранении, в частности в диагностике заболеваний и разработке лекарств.

Рассмотрим, как ИИ применяется в этих областях.

4.4.1. Диагностика заболеваний

ИИ используется для анализа медицинских изображений, таких как рентгеновские снимки, КТ- и МРТ-сканы, маммограммы и другие, с целью выявления признаков заболеваний, таких как рак, инсульт, диабет и т.д.

Сверточные нейронные сети (CNN) и другие алгоритмы машинного обучения позволяют автоматически обнаруживать и классифицировать патологии на изображениях с высокой точностью.

Вот пример на Python с использованием библиотеки OpenCV для анализа медицинских изображений КТ- и МРТ-сканов:

ЛИСТИНГ 4.26. Пример на Python с использованием библиотеки *OpenCV* для анализа медицинских изображений КТ- и МРТ-сканов

```
import cv2

# Загрузка изображения скана
image = cv2.imread('mri_scan.jpg')

# Преобразование изображения в оттенки серого
gray_image = cv2.cvtColor(image, cv2.COLOR_BGR2GRAY)

# Применение фильтрации для улучшения контраста
enhanced_image = cv2.equalizeHist(gray_image)
```

```
# Применение методов обработки изображений для выявления признаков заболеваний

# Например, можно использовать алгоритмы сегментации для выделения определенных областей
# или же алгоритмы детекции краев для обнаружения аномалий

# Отображение обработанного изображения
cv2.imshow('Enhanced Image', enhanced_image)
cv2.waitKey(0)
cv2.destroyAllWindows()
```

Этот пример демонстрирует основные шаги обработки изображений медицинских сканов, включая преобразование в оттенки серого и улучшение контраста для лучшего выявления признаков заболеваний.

Далее можно добавить специализированные алгоритмы обработки изображений в зависимости от конкретной задачи анализа сканов.

4.4.2. Разработка лекарств

ИИ помогает в поиске новых потенциальных лекарств и препаратов путем анализа биологических данных, химических свойств и молекулярных структур.

Методы **машинного обучения** и **глубокого обучения** используются для моделирования взаимодействий между лекарственными веществами и белковыми мишенями, а также для предсказания их свойств и эффективности.

Вот пример на Python с использованием библиотеки `scikit-learn` для моделирования взаимодействий между лекарственными веществами и белковыми мишенями с предсказанием их свойств и эффективности:

ЛИСТИНГ 4.27. Пример на Python с использованием библиотеки *scikit-learn* для моделирования взаимодействий между лекарственными веществами и белковыми мишенями с предсказанием их свойств и эффективности

```
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error

# Загрузка данных, например, из CSV файла
# Предположим, что у нас есть данные о химических свойствах
# лекарственных веществ и их взаимодействиях с белковыми мишенями

# X - матрица признаков (химические свойства лекарственных
# веществ)
# y - вектор целевых значений (например, эффективность
# взаимодействия)

# Разделение данных на обучающую и тестовую выборки
X_train, X_test, y_train, y_test = train_test_split(X, y, test_
size=0.2, random_state=42)

# Инициализация и обучение модели случайного леса
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X_train, y_train)

# Предсказание целевых значений для тестовой выборки
y_pred = model.predict(X_test)

# Оценка качества модели, например, с помощью среднеквадратичной
ошибки
mse = mean_squared_error(y_test, y_pred)
print("Mean Squared Error:", mse)
```

Этот пример демонстрирует основные шаги построения модели машинного обучения для предсказания свойств и эффективности взаимодействия между лекарственными веществами и белковыми мишенями.

Мы используем модель случайного леса для этой цели, но можно попробовать и другие алгоритмы машинного обучения в зависимости от конкретной задачи.

4.4.3. Поддержка в принятии решений

ИИ может помочь врачам в принятии более точных и обоснованных решений при диагностике и лечении пациентов, предоставляя информацию о возможных диагнозах, предсказаниях результатов лечения и рекомендациях по протоколам лечения.

Вот пример на Python с использованием библиотеки `scikit-learn` для построения простой модели машинного обучения, которая может помочь врачу в принятии более точного решения по диагностике и предсказанию результатов лечения:

ЛИСТИНГ 4.28. Пример на Python с использованием библиотеки *scikit-learn* для построения простой модели машинного обучения, которая может помочь врачу в принятии более точного решения по диагностике и предсказанию результатов лечения

```
from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score, classification_report

# Загрузка данных, предположим, у нас есть набор данных о пациентах
# и их диагнозах
# X - матрица признаков (характеристики пациентов, например,
# возраст, пол, результаты анализов)
# y - вектор целевых значений (диагнозы)

# Разделение данных на обучающую и тестовую выборки
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Инициализация и обучение модели случайного леса
model = RandomForestClassifier(n_estimators=100, random_state=42)
model.fit(X_train, y_train)

# Предсказание диагнозов для тестовой выборки
y_pred = model.predict(X_test)

# Оценка качества модели
accuracy = accuracy_score(y_test, y_pred)
```

```
print("Accuracy:", accuracy)

# Вывод отчета о классификации для более подробной информации о
# производительности модели
print(classification_report(y_test, y_pred))
```

Этот пример демонстрирует использование модели машинного обучения для классификации диагнозов на основе данных о пациентах. Подобные модели могут помочь врачам принимать более обоснованные решения в диагностике, а также предсказывать результаты лечения и рекомендовать соответствующие протоколы лечения на основе анализа больших объемов данных.

4.4.4. Персонализированная медицина

ИИ позволяет анализировать большие объемы медицинских данных о пациентах и создавать персонализированные подходы к диагностике и лечению на основе уникальных характеристик каждого пациента.

Это включает в себя предсказание риска развития заболеваний, выбор оптимального лечения и реагирование на индивидуальные факторы и обстоятельства пациента.

Вот пример на Python с использованием библиотеки *scikit-learn* для построения модели машинного обучения, которая предсказывает риск развития заболевания на основе уникальных характеристик пациента:

ЛИСТИНГ 4.29. Пример на Python с использованием библиотеки *scikit-learn* для построения модели машинного обучения, которая предсказывает риск развития заболевания на основе уникальных характеристик пациента

```
from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score, classification_report
```

```
# Загрузка данных, например, набора данных о пациентах с различными
# характеристиками и историей заболеваний
# X - матрица признаков (уникальные характеристики пациента,
# например, возраст, пол, история заболеваний)
# y - вектор целевых значений (риск развития заболевания, например,
# бинарная переменная: 0 - здоров, 1 - риск)

# Разделение данных на обучающую и тестовую выборки
X_train, X_test, y_train, y_test = train_test_split(X, y, test_
size=0.2, random_state=42)

# Инициализация и обучение модели случайного леса
model = RandomForestClassifier(n_estimators=100, random_state=42)
model.fit(X_train, y_train)

# Предсказание риска развития заболевания для тестовой выборки
y_pred = model.predict(X_test)

# Оценка качества модели
accuracy = accuracy_score(y_test, y_pred)
print("Accuracy:", accuracy)

# Вывод отчета о классификации для более подробной информации о
# производительности модели
print(classification_report(y_test, y_pred))
```

Этот пример демонстрирует использование модели машинного обучения для предсказания риска развития заболевания на основе уникальных характеристик пациента. Здесь данные о пациентах, такие как возраст, пол, история заболеваний и другие, используются для персонализированной оценки риска развития заболевания.

Полученные прогнозы могут помочь врачам адаптировать диагностику и лечение под индивидуальные потребности каждого пациента.

Применение искусственного интеллекта в медицине и здравоохранении может значительно повысить эффективность диагностики и лечения, улучшить результаты для пациентов и оптимизировать процессы в системе здравоохранения в целом.




Рис. 4.30. Пример генерации изображения "Робот читает книгу", Идеограм ИИ

Однако важно учитывать этические и конфиденциальные аспекты при использовании данных искусственного интеллекта в медицинской практике.

4.5. Финансы и экономика. Прогнозирование курсов валют. Оценка рисков и оптимизация инвестиций

Применение искусственного интеллекта (ИИ) в **финансах и экономике** играет ключевую роль в принятии решений, прогнозировании, оценке рисков и оптимизации инвестиций.

Рассмотрим некоторые области применения ИИ в финансах.

4.5.1. Прогнозирование курсов валют

ИИ используется для анализа макроэкономических данных, финансовых показателей, новостей и других факторов, влияющих на курсы валют. Алгоритмы машинного обучения, включая рекуррентные нейронные сети (RNN) и временные ряды, помогают в создании моделей для прогнозирования будущих изменений в курсах валют.

Вот пример на Python с использованием библиотек Pandas, Matplotlib и Sklearn для анализа макроэкономических данных, финансовых показателей и новостей и других факторов, влияющих на курс валют (для упрощения примера будем рассматривать одну валюту):

ЛИСТИНГ 4.31. Пример на Python с использованием библиотек *Pandas*, *Matplotlib* и *Sklearn* для анализа макроэкономических данных, финансовых показателей, новостей и других факторов, влияющих на курс валют (для упрощения примера будем рассматривать одну валюту)

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression

# Загрузка данных, например, курса валют и факторов, которые могут
# на него влиять (например, ставки, индексы, новости)
# Предположим, что данные хранятся в CSV файлах, которые затем
# загружаются с использованием pandas
exchange_rate_data = pd.read_csv('exchange_rate.csv')
economic_data = pd.read_csv('economic_indicators.csv')
news_data = pd.read_csv('news_sentiment.csv')

# Объединение данных в один DataFrame
```

```

merged_data = pd.merge(exchange_rate_data, economic_data, on='date')
merged_data = pd.merge(merged_data, news_data, on='date')

# Предварительная обработка данных, например, заполнение пропущенных
значений, шкалирование при необходимости

# Разделение данных на обучающую и тестовую выборки
X = merged_data.drop(['exchange_rate'], axis=1) # Входные признаки
y = merged_data['exchange_rate'] # Целевая переменная

X_train, X_test, y_train, y_test = train_test_split(X, y, test_
size=0.2, random_state=42)

# Инициализация и обучение модели линейной регрессии
model = LinearRegression()
model.fit(X_train, y_train)

# Предсказание курса валюты для тестовой выборки
y_pred = model.predict(X_test)

# Визуализация результатов
plt.scatter(y_test, y_pred)
plt.xlabel('Actual Exchange Rate')
plt.ylabel('Predicted Exchange Rate')
plt.title('Actual vs Predicted Exchange Rate')
plt.show()

```

Этот пример демонстрирует использование линейной регрессии для анализа влияния макроэкономических данных, финансовых показателей и новостей на курс валюты. Данные о курсе валюты, экономических показателях и новостях объединяются, предварительно обрабатываются и используются для обучения модели, которая затем предсказывает курс валюты на основе предоставленных факторов. Визуализация помогает оценить качество предсказаний модели.

4.5.2. Оценка рисков

ИИ используется для оценки финансовых рисков, включая кредитный риск, операционный риск, рыночный риск и др. **Модели машинного обучения** и анализа данных помогают в идентификации и предсказании потенциальных рисков, а также в разработке стратегий управления рисками.

Вот пример на Python с использованием библиотек Pandas, scikit-learn и других инструментов для оценки кредитного риска с помощью модели логистической регрессии:

ЛИСТИНГ 4.32. Пример на Python с использованием библиотек *Pandas*, *scikit-learn* и других инструментов для оценки кредитного риска с помощью модели логистической регрессии

```
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score, classification_report

# Загрузка данных, например, набора данных о кредитных заявках и их
# характеристиках
credit_data = pd.read_csv('credit_data.csv')

# Предварительная обработка данных, например, заполнение пропущенных
# значений, кодирование категориальных признаков и т. д.

# Разделение данных на обучающую и тестовую выборки
X = credit_data.drop(['default'], axis=1) # Входные признаки
y = credit_data['default'] # Целевая переменная

X_train, X_test, y_train, y_test = train_test_split(X, y, test_
size=0.2, random_state=42)

# Инициализация и обучение модели логистической регрессии
model = LogisticRegression()
model.fit(X_train, y_train)

# Предсказание дефолтности для тестовой выборки
y_pred = model.predict(X_test)

# Оценка качества модели
accuracy = accuracy_score(y_test, y_pred)
print("Accuracy:", accuracy)

# Вывод отчета о классификации для более подробной информации о
# производительности модели
print(classification_report(y_test, y_pred))
```

4.5.3. Оптимизация инвестиций

ИИ помогает в принятии решений по инвестированию путем анализа больших объемов данных, прогнозирования рыночных трендов и выявления возможностей для получения прибыли.

Алгоритмы машинного обучения используются для оптимизации портфелей инвестиций, рекомендации оптимальных стратегий и управления активами.

Вот пример на Python с использованием библиотек Pandas, scikit-learn и других инструментов для создания алгоритма принятия решений по инвестированию на основе анализа больших объемов данных и прогнозирования рыночных трендов:

ЛИСТИНГ 4.33. Пример на Python с использованием библиотек *Pandas*, *scikit-learn* и других инструментов для создания алгоритма принятия решений по инвестированию на основе анализа больших объемов данных и прогнозирования рыночных трендов

```
import pandas as pd
from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score, classification_report

# Загрузка данных, например, исторических финансовых данных,
# новостей, фундаментальных показателей компаний и т. д.
financial_data = pd.read_csv('financial_data.csv')
news_data = pd.read_csv('news_data.csv')
fundamental_data = pd.read_csv('fundamental_data.csv')

# Предварительная обработка и объединение данных
# Например, соединение данных о финансах, новостях и
# фундаментальных показателях по дате и компании
```

```

# Создание целевой переменной: например, сигнал инвестирования
(покупка/продажа/удержание)
# Это может быть основано на рыночных трендах, фундаментальных
показателях и сентименте новостей

# Разделение данных на обучающую и тестовую выборки
X = merged_data.drop(['investment_signal'], axis=1) # Входные
признаки
y = merged_data['investment_signal'] # Целевая переменная

X_train, X_test, y_train, y_test = train_test_split(X, y, test_
size=0.2, random_state=42)

# Инициализация и обучение модели случайного леса для классификации
сигналов инвестирования
model = RandomForestClassifier(n_estimators=100, random_state=42)
model.fit(X_train, y_train)

# Предсказание сигналов инвестирования для тестовой выборки
y_pred = model.predict(X_test)

# Оценка качества модели
accuracy = accuracy_score(y_test, y_pred)
print("Accuracy:", accuracy)

# Вывод отчета о классификации для более подробной информации о
производительности модели
print(classification_report(y_test, y_pred))

```

4.5.4. Торговля на финансовых рынках

ИИ применяется для автоматизации торговых стратегий на финансовых рынках, включая Форекс, фондовые биржи, криптовалютные рынки и другие.

Алгоритмы машинного обучения и нейронные сети используются для создания торговых сигналов, прогнозирования цен и определения оптимальных моментов для покупки и продажи активов.

Вот пример на Python с использованием библиотек Pandas, NumPy и TA-Lib (Technical Analysis Library) для создания простого алгоритма автоматизации торговых стратегий на финансовых рынках, таких как Форекс или фондовые биржи:

ЛИСТИНГ 4.34. Пример на Python с использованием библиотек *Pandas*, *NumPy* и *TA-Lib* для создания простого алгоритма автоматизации торговых стратегий на финансовых рынках, таких как Форекс или фондовые биржи

```
import pandas as pd
import numpy as np
import ta
import matplotlib.pyplot as plt

# Загрузка исторических финансовых данных (например, цены закрытия)
data = pd.read_csv('financial_data.csv')

# Предварительная обработка данных
# Например, расчет технических индикаторов (например, скользящая
# средняя, RSI и т. д.)

# Расчет скользящих средних
data['SMA_20'] = ta.trend.sma_indicator(data['Close'], window=20)
data['SMA_50'] = ta.trend.sma_indicator(data['Close'], window=50)

# Расчет RSI
data['RSI'] = ta.momentum.rsi(data['Close'], window=14)

# Создание сигналов покупки и продажи на основе стратегии
# (например, пересечение скользящих средних и RSI)
data['Buy_Signal'] = np.where((data['SMA_20'] > data['SMA_50']) &
                              (data['RSI'] < 30), 1, 0)
data['Sell_Signal'] = np.where((data['SMA_20'] < data['SMA_50']) &
                              (data['RSI'] > 70), -1, 0)

# Визуализация цен закрытия и сигналов покупки/продажи
plt.figure(figsize=(12,6))
plt.plot(data['Close'], label='Close Price', alpha=0.5)
plt.scatter(data.index, data['Close'], marker='o', c=data['Buy_
Signal'], cmap='spring', label='Buy Signal', lw=1)
plt.scatter(data.index, data['Close'], marker='o', c=data['Sell_
Signal'], cmap='autumn', label='Sell Signal', lw=1)
plt.title('Trading Signals')
```

```
plt.xlabel('Date')  
plt.ylabel('Close Price')  
plt.legend()  
plt.show()
```

Этот пример демонстрирует создание алгоритма автоматизации торговых стратегий на финансовых рынках с использованием простых технических индикаторов, таких как скользящие средние и RSI (индекс относительной силы).

Стратегия основывается на пересечении скользящих средних и условиях RSI для определения оптимальных моментов покупки и продажи активов. Результаты визуализируются на графике цен закрытия с отмеченными сигналами покупки и продажи.



ПРИМЕЧАНИЕ. Применение искусственного интеллекта в финансах и экономике может повысить эффективность принятия решений, улучшить результаты инвестирования и управления рисками, а также оптимизировать процессы на финансовых рынках. Однако важно учитывать этические и регуляторные аспекты при использовании ИИ в финансовой сфере.

4.6. Прочие области применения ИИ

Конечно, существует множество других областей применения нейронных сетей, которые мы не упомянули ранее. Вот несколько дополнительных областей.

4.6.1. Автономные транспортные системы

Нейронные сети применяются для разработки систем управления автономными автомобилями, дронами и другими транспортными средствами.

Эти системы используют **комплексные модели машинного обучения** для восприятия окружающей среды, принятия решений и планирования маршрутов.

4.6.2. Промышленная автоматизация

Нейронные сети применяются для **контроля и оптимизации** таких промышленных процессов, как производство, логистика и снабжение.

Системы машинного обучения позволяют **автоматизировать процессы контроля качества**, оптимизировать производственные цепочки и улучшать энергоэффективность.

4.6.3. Энергетика и экология

Нейронные сети используются для **оптимизации работы энергетических систем**, прогнозирования потребления энергии и определения оптимальных методов энергосбережения.

Технологии машинного обучения помогают в мониторинге и анализе экологических данных, таких как загрязнение воздуха, климатические изменения и управление отходами.

Эти области демонстрируют разнообразие применения нейронных сетей в различных сферах жизни и промышленности. Исследования и разработки в области искусственного интеллекта продолжают расширять возможности

его применения, и мы можем ожидать появления новых инновационных решений в ближайшие годы.

4.7. Перспективы развития ИИ в ближайшем будущем

Рассмотрим для начала, как можно классифицировать уровень развития современных нейросетей по сравнению с уровнем развития нейронных сетей человека.

В Интернете можно найти множество статей и видео с рассуждениями об опасности внедрения нейросетей в человеческую жизнь, сейчас и в будущем. В связи с этим муссируются различные конспирологические теории, вплоть до сценариев, показанных в фантастических романах и некоторых фантастических сериалах, где ИИ в разных ипостасях поработает и уничтожает человечество (например, как конкурента в борьбе за материальные ресурсы) с самыми ужасающими подробностями.

В связи с этим невольно возникают вопросы:

- Насколько реальны такие сценарии?
- Что представляют из себя на самом деле современные нейросети?

Попытаемся ответить на эти вопросы и начнем со второго.

Что представляют из себя на самом деле современные нейросети?

В статье от Microsoft "Искры сильного искусственного интеллекта: Ранние эксперименты с GPT-4" утверждается, что ранняя версия GPT-4 представляет собой "более высокий уровень общего интеллекта, чем предыдущие модели ИИ". Далее приводится ряд аргументов, благодаря которым эту нейросеть объявляют пусть и не полной, но все же весьма продвинутой версией ИИ с возможностью причисления ее к СИЛЬНОМУ ИИ (AGI).

Что такое Сильный ИИ?

Рассмотрим три стадии развития ИИ:




Рис. 4.35. Условная схема развития искусственного интеллекта

На рисунке выше можно увидеть условную схему развития искусственного интеллекта.

На какой же стадии находятся современные нейросети? Это узкий или слабый ИИ. По мнению некоторых исследователей, приблизительно к 2040 году возможно появление Сильного ИИ. И уже позднее — Супер ИИ.

Так что сейчас мы можем довольствоваться тем, что есть. Приведу цитаты из замечательного исследования Руслана Ахтямова, от 23 октября 2023 года, выложенной на сайте ВКонтакте. Он задавал вопросы на вышеозначенную тему наиболее "продвинутым" нейросетям.

Вот что Руслан пишет по вопросу причисления СРТ-4 к некоторым аспектам Сильного ИИ:

"Многие критики GPT-4 продолжают утверждать, что все еще не решена проблема галлюцинаций (когда ИИ придумывает нереальные ответы), не решена проблема надежности, не решено планирование сложных задач. Если под "AGI" мы подразумеваем получение машины, которая будет столь же "умной", как человек, то почему проблема галлюцинаций, очень человеческой черты, является проблемой? Разве умение врать и наличие человекоподобной галлюцинации не является подтверждением следующего технологического прорыва?"

В 1833 году современники Чарльза Бэббиджа называли его механический калькулятор или, как мы бы назвали его сегодня, механический компьютер общего назначения, "мыслящей машиной". В 1949 году пионер компьютерной техники Эдмунд Беркли написал в книге "Гигантские мозги или машины, которые думают":

"В последнее время появилось много новостей о странных гигантских машинах, которые могут обрабатывать информацию с огромной скоростью и мастерством... Эти машины похожи на мозг, если бы он был сделан из железа и проводов, а не из плоти и нервов... Машина может работать с информацией; она может вычислять, делать выводы и выбирать; она может выполнять разумные операции с информацией. Машина, следовательно, может мыслить".

Другие пионеры компьютерной техники, такие как Морис Уилкс и Артур Сэмюэл, считали, что вопрос о том, могут ли машины мыслить — или смогут ли они вообще — зависит от того, как мы определяем понятие "мышление". К сожалению, определение того, о чем идет речь, сегодня считается очень старомодным. Например, в недавнем двухлетнем исследовании, проведенном

большой группой выдающихся исследователей искусственного интеллекта с целью определения исходных данных для "Столетнего исследования искусственного интеллекта", было заявлено, что отсутствие четкого определения того, что они изучают, на самом деле является положительным моментом.

И мы обвиняем ChatGPT в том, что у него "галлюцинации"?

Мне захотелось провести собственное расследование, и я спросил у ChatGPT (версия от 14 марта), каково определение AGI, и вот что я получил в ответ:

"Сильный Искусственный интеллект (AGI) — это теоретический тип искусственного интеллекта, обладающий человекоподобными когнитивными способностями, такими как способность учиться, рассуждать, решать проблемы и общаться на естественном языке".

Я задал тот же вопрос в чате Bing Chat компании Microsoft (который, предположительно, основан на ChatGPT) и получил в ответ следующее:

"Сильный Искусственный интеллект (Artificial General Intelligence, AGI) — это представление обобщенных когнитивных способностей человека в программном обеспечении таким образом, чтобы, столкнувшись с незнакомой задачей, система AGI могла найти решение. Замысел системы AGI состоит в том, чтобы выполнить любую задачу, на которую способен человек [1]. Именно интеллект машин позволяет им понимать, обучаться и выполнять интеллектуальные задачи подобно человеку. С помощью AGI машины могут имитировать человеческий разум и поведение для решения любых сложных задач [2]".

В отличие от ChatGPT, Bing Chat приводит свои источники и ссылается на них. [1] — это новостной сайт Tech Target; [2] — статья, написанная исследователем ИИ и опубликованная на Spiceworks. Для убедительности Bing добавляет третий источник (но на него ответ не опирается?) — статью Википедии об AGI.

Ответы несколько отличаются, но для моего скромного человеческого интеллекта они оба написаны в соответствии с нашими коллективными галлюцинациями и нечеткими формулировками относительно мыслящих машин и искусственного интеллекта.

Теперь, в интересах полного раскрытия информации, позвольте мне сказать, что я ожидал, что чат-боты будут серьезно галлюцинировать, потому что у меня возникла идея проверить их определение AGI после того, как я обнаружил, насколько запутаны и сбиты с толку их человеческие создатели, и, по правде говоря, я ожидал, что их искусственные потомки будут так же запутаны.

На сайте OpenAI можно найти такое определение AGI:

"Высокоавтономные системы, превосходящие человека в выполнении наиболее экономически ценной работы". Никаких пояснений по поводу "высокой автономности" не приводится, поэтому можно сделать вывод, что ранние "гигантские мозги", которые уже вычисляли быстрее человека, относятся к AGI (Алан Тьюринг в 1947 г. подсчитал, что один из таких гигантских мозгов – ACE – мог "выполнять работу примерно 10 000 [человеческих] компьютеров").

Это "определение" AGI фигурирует в уставе OpenAI 2018 года, в котором обещано, что AGI, являющаяся конечной целью организации, "принесет пользу всему человечеству". Однако, учитывая последние события и всемирную известность, генеральный директор OpenAI Сэм Альтман 24 февраля 2023 г. опубликовал документ "Планирование AGI и далее", в котором пересмотрел (обновил?) определение AGI:

"Наша миссия заключается в том, чтобы искусственный интеллект общего назначения — система, которая в целом умнее человека, — принес пользу всему человечеству".

Как видите, ссылка ведет на устав, в котором по-прежнему фигурирует прежнее определение.

Человеческому интеллекту удобны расплывчатые, круговые, разнородные, даже противоречивые определения. Человеческий интеллект предается галлюцинациям, причем с момента появления современной науки и техники, в частности галлюцинациям о том, что человек является богоподобным творцом. Недавно эти галлюцинации были модернизированы и стали представлять человека даже лучше, чем Бог, поскольку специалисты по искусственному интеллекту, несомненно, создадут интеллектуальную машину, которая будет умнее, нравственнее, менее предвзятой, чем человек.

Впечатленный тем, что ChatGPT не стал следовать запутанному языку и многочисленным определениям своих создателей, я вернулся и спросил у доброго чат-бота: "Проявляешь ли ты искры интеллекта?"

"Я являюсь языковой моделью ИИ и предназначен для имитации человекоподобного интеллекта при выполнении определенных задач, таких как генерация ответов на вводимые пользователем данные. Я обучался на больших объемах текстовых данных и научился распознавать закономерности и взаимосвязи в языке, что позволяет мне генерировать ответы, соответствующие контексту и грамматически правильные. Однако важно отметить, что мой интеллект ограничен конкретной задачей, для решения которой я был обучен, и я не обладаю таким же уровнем общего интеллекта или когнитивных способностей, как человек. Хотя мои ответы могут казаться разумными, в конечном итоге они генерируются набором запрограммированных правил и статистических алгоритмов, а не являются истинным рассуждением или пониманием".

Тут только можно привести вопрос Руслана в конце данной статьи "Что скажете: стоит нам довериться машине?" Решать вам. Так же как искать ответы на второй вопрос: возможны ли апокалипсические сценарии развития искусственного интеллекта в будущем?

Вернемся к теме главы и рассмотрим возможные позитивные направления использования нейронных сетей в ближайшем и отдаленном будущем.

Они включает в себя следующие аспекты:



Рис. 4.36. Пример генерации изображения нейронных сетей в образе андроида, Идеограм ИИ

4.7.1. Медицинские технологии

В ближайшем будущем нейронные сети будут активно применяться в медицинских технологиях для улучшения диагностики, лечения и управления здоровьем. В отдаленном будущем можно ожидать дальнейшего развития персонализированной медицины на основе анализа генома, клинических данных и других факторов с использованием технологий искусственного интеллекта.

4.7.2. Энергетика и экология

Также в ближайшем будущем нейронные сети будут применяться для оптимизации работы энергетических систем, управления ресурсами и решения проблем, связанных с изменением климата. В отдаленном будущем можно ожидать развития новых технологий для производства чистой энергии, устойчивого развития и охраны окружающей среды с использованием искусственного интеллекта.

4.7.3. Пространственные исследования и колонизация космоса

В ближайшем будущем нейронные сети будут применяться для управления автономными системами и роботами в недрах, океанах и морях Земли и в космосе, мониторинга условий на космических объектах и обеспечения безопасности миссий.

В отдаленном будущем можно ожидать использования искусственного интеллекта для создания самообучающихся систем, адаптирующихся к новым условиям и задачам на Земле и в космосе, а также для развития технологий колонизации других планет и космических объектов.

В целом, нейронные сети имеют потенциал преобразить множество областей жизни и деятельности как на Земле, так и в космическом пространстве. Исследования и разработки в области искусственного интеллекта продолжают расширять границы его применения и открывать новые возможности для прогресса человечества.



Рис. 4.37. Пример генерации изображения нейросетей в образе андроида, Идеограм ИИ

Перспективы применения нейронных сетей и искусственного интеллекта в целом действительно огромные. С их помощью мы можем решать сложные задачи, улучшать качество жизни людей, исследовать Землю и космос, сохранять окружающую среду и многое другое.

Важно продолжать инвестировать в исследования и разработки в этой области, чтобы максимально раскрыть потенциал и преимущества искусственного интеллекта для человечества.

Глава 5.

Этические и социальные аспекты нейросетей. Влияние нейросетей на общество

Решение этических и социальных вопросов создания, развития и применения нейросетей все больше волнует людей.

Рассмотрим несколько ключевых проблем.

5.1. Прозрачность и объяснимость

Важно, чтобы нейронные сети были прозрачными и объяснимыми в своих решениях, особенно в областях, где эти решения могут оказывать влияние на жизнь людей, таких как медицина, финансы, правосудие и многих других.

Для этого имеется ряд важных аспектов:

- **Доверие пользователей.** Понимание пользователем, почему ИИ дало ему определенный совет, рекомендацию или прогноз способствует росту доверия.
- **Доказательность решения.** Если ИИ дает определенную рекомендацию или решение, когда ответы касаются медицины, юриспруденции или других важных аспектов жизни человека, эти ответы должны быть доказательными.
- **Выявление ошибок.** Прозрачность и объяснимость должны помогать ученым и разработчикам находить и ликвидировать возможные ошибки, смещения в моделях ИИ.
- **Понимание и интерпретация.** Объяснимость может помочь понимать и интерпретировать модели и решения, обучаться и профессионально расти.

Основными направлениями достижения объяснимости и роста доверия к решениям нейросетей могут быть: **метод локальной интерпретации, визуализация данных и результатов решений модели, использование деревьев решений и линейных моделей** вместо так называемых «черных ящиков», разработка специальных архитектур нейросетей с более понятными результатами, такими как CNN и RNN, использование ансамблей моделей.

Увеличение объяснимости и рост доверия к решениям нейросетей могут столкнуться со сложными вызовами. Разработчикам и исследователям нужно находить некую золотую середину в продвижении этих идей. Они могут столкнуться с ухудшением точности модели, отсутствием универсальных методов, недостатками в обучении пользователей нейросетей и специалистов, сложностями в решении этических вопросов, гарантирующих прозрачность, ответственность и защиту данных.

Объяснимость – важное направление исследований в области искусственного интеллекта.

5.2. Безопасность и приватность данных

Необходимо обеспечивать безопасность и приватность данных, используемых для обучения нейронных сетей, чтобы защитить личную информацию пользователей и избежать возможности злоупотребления этой информацией. Важность и необходимость этого не вызывает никаких сомнений.

5.3. Справедливость и предвзятость

Нейронные сети могут быть подвержены предвзятости и неравенству данных, что может привести к несправедливым решениям и дискриминации. Важно учитывать этот аспект при разработке и использовании нейросетей в целях справедливости.

5.4. Работа и занятость

Внедрение нейросетей и автоматизация процессов могут изменить структуру рынка труда и привести к сокращению рабочих мест в некоторых отраслях.

Важно разрабатывать стратегии переквалификации и обучения для поддержки людей, чьи рабочие места могут быть затронуты.

5.5. Экономическое неравенство

Использование нейросетей может усилить экономическое неравенство, поскольку доступ к новым технологиям и возможностям может быть ограничен.

Важно обеспечить **доступность и равноправие** при использовании нейронных сетей.

Общество должно активно обсуждать и учитывать эти этические и социальные аспекты при разработке и использовании нейросетей. Только так мы сможем создать технологии, которые будут способствовать благополучию и прогрессу всего общества.

5.6. Положительные стороны использования нейросетей

Использование искусственного интеллекта (ИИ) обладает множеством положительных сторон, включая автоматизацию и упрощение жизни.

Перечислим некоторые из них.

5.6.1. Автоматизация рутинных задач

ИИ позволяет автоматизировать **множество рутинных задач**, освобождая время людей для выполнения более творческих и стратегических заданий.

Это может включать в себя автоматизацию процессов в производстве, бизнесе, административной работе и других областях.

5.6.2. Улучшение точности и эффективности

Использование ИИ может повысить **точность и эффективность выполнения задач** за счет автоматического анализа данных, принятия решений на основе больших объемов информации и оптимизации процессов.

Это применимо в медицине, финансах, производстве, логистике, на транспорте и в других отраслях.

5.6.3. Повышение безопасности и комфорта

ИИ используется для создания **систем безопасности и управления ресурсами**, обеспечивая более высокий уровень безопасности и комфорта для людей.

Примерами могут служить системы видеонаблюдения, умные дома, системы управления транспортом и др.




Рис. 5.1. Пример генерации изображения нейросетей в образе андроида, Леонардо ИИ

5.6.4. Предоставление персонализированных услуг

ИИ позволяет создавать **персонализированные услуги и продукты**, учитывая индивидуальные потребности и предпочтения пользователей.

Это может быть достигнуто за счет анализа данных о поведении и предпочтениях пользователей в Интернете, социальных сетях и других источниках.

5.6.5. Развитие новых технологий и инноваций

Использование ИИ стимулирует развитие новых технологий, инноваций и решений, способствуя прогрессу в различных отраслях и улучшению качества жизни.

Эти положительные аспекты использования ИИ помогают **упростить повседневную жизнь** людей, повысить **эффективность работы** и **улучшить качество услуг и продуктов**.

Однако важно также учитывать этические и социальные аспекты внедрения ИИ, чтобы обеспечить его эффективное и ответственное использование.

5.7. Отрицательные стороны использования нейросетей

Использование нейросетей и искусственного интеллекта в целом также сопряжено с некоторыми отрицательными аспектами, включая потерю рабочих мест и возникновение неравенства.

Рассмотрим некоторые из них.

5.7.1. Потеря рабочих мест

Автоматизация и внедрение нейросетей могут привести к **сокращению рабочих мест** в некоторых отраслях, особенно там, где рутинные задачи могут быть легко автоматизированы.

Работники, занятые в таких сферах, могут столкнуться с трудностями при поиске новой работы или необходимостью переквалификации.

5.7.2. Экономическое неравенство

Внедрение нейросетей может усилить **экономическое неравенство**, так как доступ к новым технологиям и возможностям может быть ограничен.

Люди с навыками и образованием, соответствующими требованиям рынка труда, могут получать больше возможностей и заработка, что способно привести к увеличению разрыва между богатыми и бедными.

5.7.3. Предвзятость и дискриминация

Нейросети могут быть подвержены **предвзятости и дискриминации**, основанной на данных, на которых они обучаются.

Это может привести к несправедливым решениям в таких областях, как прием на работу, выдача кредитов, судебные решения и другие.

5.7.4. Потеря контроля

Использование нейросетей может привести к **потере контроля над процессами принятия решений** и действиями систем.

Это может вызвать опасения относительно безопасности и надежности автоматических систем и устройств.

5.7.5. Социальные проблемы и вызовы

Внедрение нейросетей может создавать новые социальные проблемы и вызовы, такие как **угроза приватности, недостаток доверия к автоматизированным системам** и др.

Эти отрицательные аспекты подчеркивают необходимость балансировки между развитием технологий и учетом их социальных и этических последствий. Важно разрабатывать и использовать нейросети с учетом этих аспектов, чтобы обеспечить их эффективное и ответственное использование в обществе.

5.8. Возможные решения и регулирование. Создание этического кодекса нейросетей

Урегулирование отрицательных сторон использования искусственного интеллекта (ИИ) основывается на нескольких ключевых принципах, перечислим их.

5.8.1. Прозрачность и открытость

Важно, чтобы разработчики и пользователи ИИ были осведомлены о том, какие данные используются для обучения систем, какие алгоритмы применяются и как принимаются решения.

Прозрачность и открытость помогают обнаруживать и исправлять проблемы предвзятости, дискриминации и других аспектов, которые могут повлиять на безопасность и справедливость систем.

5.8.2. Этические принципы и стандарты

Необходимо разработать и соблюдать **этические принципы и стандарты использования ИИ**, которые учитывают права и интересы всех заинтересованных сторон.

Это может включать в себя оценку воздействия ИИ на общество, защиту приватности данных, справедливость и равноправие.

5.8.3. Обучение и образование

Важно обучать пользователей и разработчиков ИИ **этическим и социальным аспектам** его использования, а также способам минимизации отрицательных последствий.

Это помогает повысить осведомленность и компетентность в области использования ИИ.



Рис. 5.2. Генерация изображения образа нейросетей, Леонардо ИИ

5.8.4. Регулирование и законодательство

Необходимо разработать соответствующее **законодательство** и **регулирование**, которые будут контролировать использование ИИ и защищать интересы общества и его членов.

Регулирование должно учитывать различные аспекты, такие как защита данных, прозрачность алгоритмов, ответственность за решения ИИ и другие.

5.8.5. Международное сотрудничество и стандартизация

Важно содействовать **международному сотрудничеству** и **стандартизации в области ИИ**, чтобы разработать общие нормы и принципы, которые будут применяться в различных странах и областях.

Урегулирование отрицательных сторон использования ИИ требует комплексного подхода и учета различных факторов. Оно должно стремиться к балансу между стимулированием инноваций и обеспечением безопасности, справедливости и защиты прав и интересов людей.

5.9. Создание этического кодекса нейросетей

Создание **этического кодекса для нейросетей** является важным шагом для обеспечения ответственного и этичного использования искусственного интеллекта. Этот кодекс может включать в себя руководящие принципы и стандарты поведения для разработчиков, пользователей и других заинтересованных сторон.

Вот несколько причин, почему создание этического кодекса нейросетей важно.

5.9.1. Защита прав и интересов людей

Этический кодекс может помочь защитить права и интересы людей, использующих нейросети и подвергающихся их воздействию, включая права на приватность, безопасность и справедливость.

5.9.2. Предотвращение негативных последствий

Кодекс может помочь предотвратить негативные последствия использования нейросетей, такие как предвзятость, дискриминация, угрозы безопасности и другие.

5.9.3. Установление стандартов

Этический кодекс может установить стандарты и руководящие принципы для разработки, обучения и использования нейросетей, что способствует их эффективному и ответственному применению.

5.9.4. Повышение доверия общества

Создание этического кодекса может повысить доверие общества к нейросетям и искусственному интеллекту в целом, показывая, что их развитие и использование происходит с учетом этических принципов.

5.9.5. Развитие сообщества и профессионализма

Кодекс может способствовать развитию сообщества профессионалов в области нейросетей и создать основу для дальнейшего сотрудничества и обмена

опытом. Создание этического кодекса для нейросетей требует участия различных заинтересованных сторон, включая ученых, разработчиков, правительства, общественные организации и других.

Это должен быть процесс, основанный на диалоге и консенсусе, который учитывает широкий спектр этических, социальных и правовых вопросов, связанных с использованием нейросетей.

5.9.6. Обучение

Развитие обучения и образования в области нейросетей является крайне важным.

Вот несколько причин этого:

- **Расширение возможностей.** Обучение людей в области нейросетей дает им возможность понять, как эти технологии работают и как их можно применять для решения реальных проблем в различных сферах жизни.
- **Повышение конкурентоспособности.** Знание нейросетей и искусственного интеллекта может повысить конкурентоспособность работников на рынке труда, так как эти технологии становятся все более востребованными в различных отраслях.
- **Создание новых возможностей.** Образование в области нейросетей может способствовать созданию новых возможностей для карьерного роста и развития, включая работу в области исследований, разработки, консультирования и других.
- **Подготовка к будущему.** Искусственный интеллект и нейросети играют все более важную роль в нашем обществе, и в будущем спрос на специалистов в этой области будет только расти. Поэтому обучение в этой сфере помогает людям быть готовыми к вызовам и возможностям будущего.
- **Этическое использование.** Образование также играет ключевую роль в обеспечении этичного и ответственного использования нейросетей. Чем

больше люди знают об этой технологии и ее потенциальных последствиях, тем лучше они могут принимать обоснованные решения и влиять на развитие этой области в целом.

Таким образом, развитие **обучения и образования** в сфере нейросетей является ключевым фактором для успешного применения этой технологии в обществе.

5.9.7. Регулирование и контроль использования нейросетей

Считаю, что регулирование и контроль использования нейросетей необходимы. Некоторые из этих вопросов уже затрагивались, однако стоит их отметить еще раз.

Вот несколько причин, почему это важно:

- **Безопасность и защита данных.** Регулирование помогает обеспечить безопасность и защиту данных, используемых в нейросетях. Это включает в себя обеспечение конфиденциальности личной информации и предотвращение утечек данных.
- **Этические и социальные аспекты.** Регулирование может помочь учитывать этические и социальные аспекты использования нейросетей, такие как предвзятость, дискриминация и справедливость. Это позволяет обеспечить более справедливое и этичное применение технологии.
- **Ответственность и прозрачность.** Регулирование помогает установить ответственность за решения, принимаемые нейросетями, и обеспечить прозрачность в их работе. Это важно для обеспечения доверия пользователей и общества к этой технологии.
- **Предотвращение негативных последствий.** Регулирование может помочь предотвратить негативные последствия использования нейросетей, такие как угрозы безопасности, потеря рабочих мест и экономическое неравенство.

- **Стимулирование инноваций.** Хорошо сбалансированное регулирование может способствовать стимулированию инноваций в области нейросетей, обеспечивая безопасную и эффективную среду для развития технологий.

Однако важно, чтобы регулирование было сбалансированным и учитывало потребности и интересы всех заинтересованных сторон, включая разработчиков, пользователей, правительство и общество в целом. Только так мы сможем обеспечить ответственное и устойчивое использование нейросетей в нашем обществе.

5.9.7. Будущее взаимодействие нейросетей и человечества

Будущее взаимодействие нейросетей и человечества связано с оптимизмом и даже с осторожным оптимизмом.

Нейросети и искусственный интеллект (ИИ) имеют огромный потенциал для улучшения качества жизни людей, решения сложных проблем и создания новых возможностей.

Вот несколько ключевых аспектов:

- **Сотрудничество:** будущее взаимодействия нейросетей и человечества, на мой взгляд, будет основано на сотрудничестве. Люди и нейросети будут работать вместе, дополняя друг друга и усиливая свои сильные стороны.
- **Развитие новых технологий и инноваций:** нейросети будут продолжать развиваться и становиться все более мощными и универсальными инструментами. Это приведет к развитию новых технологий и инноваций в различных областях, таких как медицина, транспорт, образование, искусство и другие.

- **Этическое и ответственное использование:** важно, чтобы взаимодействие нейросетей и человечества происходило с соблюдением этических принципов и учитывало интересы и потребности людей. Необходимо обеспечить прозрачность, справедливость и безопасность в использовании этих технологий.
- **Решение глобальных проблем:** нейросети могут сыграть ключевую роль в решении глобальных проблем, таких как изменение климата, борьба с болезнями, бедность и неравенство. Они могут помочь анализировать и прогнозировать сложные системы, обрабатывать большие объемы данных и разрабатывать новые стратегии и решения.
- **Обеспечение доступности и инклюзивности:** важно, чтобы развитие нейросетей учитывало интересы всех слоев общества и обеспечивало их доступность и инклюзивность. Это включает в себя разработку технологий, которые учитывают различные культурные, социальные и экономические контексты.

В целом будущее взаимодействия нейросетей и человечества представляется мне вдохновляющим и полным возможностей. Однако важно помнить о том, что успешное взаимодействие требует сбалансированного подхода, который учитывает интересы и потребности всех заинтересованных сторон.

5.9.8. Перспективы развития нейросетей

Перспективы развития нейросетей включают в себя оптимизм относительно их потенциала для продолжения инноваций и улучшения.

В будущем можно ожидать следующих направлений развития:

- **Улучшение существующих моделей.** Современные нейросети будут продолжать развиваться и совершенствоваться, становясь более эффективными, точными и адаптивными. Это включает в себя разработку новых архитектур, оптимизацию алгоритмов обучения и улучшение производительности.

- **Использование квантовых вычислений.** В будущем квантовые нейросети могут стать более распространенными, позволяя решать сложные задачи, которые в настоящее время недоступны классическим вычислительным методам. Квантовые вычисления могут значительно ускорить обучение и предсказание нейронных сетей.
- **Развитие биоморфных нейросетей.** Биоморфные нейросети, вдохновленные биологическими системами, такими как мозг, также могут стать предметом активного исследования и развития. Эти модели могут обладать уникальными свойствами, такими как устойчивость к помехам и способность к самоорганизации.
- **Интеграция с другими технологиями.** Нейросети будут все более интегрироваться с другими технологиями, такими как квантовые вычисления, биоинформатика, робототехника и Интернет вещей. Это может привести к созданию новых, более сложных и мощных систем.
- **Расширение областей применения.** В будущем нейросети будут все шире применяться в различных отраслях, включая медицину, транспорт, производство, финансы, искусство и многое другое. Это может привести к значительному улучшению качества жизни людей и решению сложных социальных и экономических проблем.

Таким образом, перспективы развития нейросетей включают в себя широкий спектр возможностей, в том числе и переход к квантовым и биоморфным моделям. Однако для успешной реализации этих перспектив требуются дальнейшие исследования, инновации и сотрудничество в области искусственного интеллекта.

5.9.9. Нейросети и скрытые законы Вселенной

Теория о применении золотого сечения или последовательности Фибоначчи в различных аспектах нашей Вселенной является интересной и интригующей. Однако, когда речь идет о развитии нейросетей, эти концепции обычно не используются в прямом смысле.

Нейронные сети обучаются на основе данных и алгоритмов оптимизации, их архитектура и параметры обычно определяются эмпирически, на основе практических знаний и опыта. В то время как некоторые аспекты идеи золотого сечения могут присутствовать в архитектуре нейросетей или алгоритмах обучения, это скорее исключение, чем общее правило.

Например, исследователи могут применять принципы золотого сечения при разработке определенных слоев или модулей нейросети для достижения определенных характеристик, таких как равномерное распределение весов или оптимальная производительность. Однако в целом развитие нейросетей скорее определяется эффективностью и функциональностью, чем строгими математическими закономерностями, такими как золотое сечение.

Таким образом, хотя некоторые концепции и принципы математики могут быть внедрены в развитие нейросетей, они обычно не играют определяющей роли в их создании и обучении.

Заключение

Так чем же являются современные нейросети?

Понятно, что их развитие уже не остановить. Стоит ли этого бояться?

Понятно, что вряд ли ИИ в ближайшие годы хотя бы приблизится к уровню самосознания человека. Поэтому в обозримом будущем человечеству не грозит тотальная безработица.

Стоит также задуматься о том, что творческая энергия человека может создавать гениальные произведения искусства в разных областях. В то же время похожие «изделия» от ИИ будут лишь хорошей имитацией.

Так как за картиной, романом или доказанной усилиями человека теоремой есть что-то большее, чем просто краска на холсте, некие тексты и строчки формул.

Уверена, что по самым «веселым» сценариям, рождающимся в головах некоторых конспирологов, восстание машин, зачистка Земли от человечества нам тоже не угрожает. Сейчас нейронные сети — это инструмент. А вот как люди будут пользоваться этим инструментом, зависит только от самих людей.

Именно поэтому, как считают многие люди, например глава Tesla и Twitter Илон Маск и сооснователь Apple Стив Возняк, необходимы протоколы безопасности при работе с нейросетями.

Однако кто же будет писать эти протоколы? Вначале стоит определиться с этим. Ведь пока все это остается на уровне благих пожеланий.

Будут ли они на самом деле соблюдаться?

Кто будет осуществлять надзор за соблюдением правил?

Мы разобрали чуть выше, чем же могут быть опасны нейросети.

На самом деле опасность при использовании нейросетей, как уже отмечалось, могут представлять лишь злоумышленники.

Да, с помощью ИИ, например языковой модели, можно написать курсовую или диплом, иную работу, а можно замыслить и осуществить какую-нибудь деятельность негативного характера. Например, поток многочисленных фейков в интернет-пространстве.

Если нейросеть будет неправильно распознавать лица, то это может привести к арестам невинных людей. Возможны шантаж, вымогательство, кража данных, кибератаки с помощью нейросетей. Взлом паролей, кардинг, взлом систем безопасности, социальная инженерия с целью обмана. Но все это возможно лишь с участием человека. Сами по себе нейросети на все эти действия на данный момент неспособны.

Так что пока нейросети — это **инструмент**.

Которому, тем не менее, не стоит доверять чрезмерно сложные задачи.

Потеря рабочих мест возможна. Но с развитием нейросетей будут появляться новые рабочие места, связанные с разработкой, установкой, программированием и курированием этих систем.

Творческие задачи в исполнении нейросетей возможны, но без чрезмерно критичного отношения к их качеству. В медицине можно выборочно доверять некоторые работы нейросетям.

Восстание машин? Страшилка для несведущих людей.

Тут, скорее, стоит бояться исследователей без моральных ограничений в этой области.

Если подвести итог, то можно констатировать очевидный факт: остановить развитие и обучение нейросетей невозможно. И здесь опять встает вопрос создания эффективных механизмов регулирования искусственного интеллекта и инструментов четкого понимания принимаемых им решений. Впереди много работы.

Список использованных источников информации

- Джуда Перл, The Book of Why, 2018 г.;
- Прикладная линейная алгебра для исследователей данных, Майк Козн, 2023;
- Нейронные сети и глубокое обучение, Майкл Нильсен;
- Axler Sheldon, Linear Algebra Done Right, Springer, 2014.
- Mathematical Statistics and Data Analysis, John A. Rice, 1994.
- T. Hastie, R. Tibshirani, J. Friedman - The Elements of Statistical Learning (2nd Edition), Springer, 2009.
- Аггарвал Чару, Нейронные сети и глубокое обучение, учебный курс, Вильямс, Россия, 2020.
- Майкл Нильсен, Neural Networks and Deep Learning.
- Гудфеллоу Я., Бенджио И., Курвилль А., Глубокое обучение, 2017 г.
- Сандро Сканси, Introduction to Deep Learning, 2018 г.
- Кристоф Молнар, Interpretable Machine Learning, 2019 г.
- Фрэнк Розенблатт, The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, 1958.
- Adaptive linear Neuron, Widrow & Hoff, 1960.
- Neocognitron: A Hierarchical Neural Network Capable of Visual Pattern Recognition, KUNIHICO FUKUSHIMA, 1980.
- Parallel Distributed Processing: Explorations in the Microstructure of Cognition, RUMELHART ET AL., 1986.

- A recurrent error propagation network speech recognition system, recognition system, T. Robinson, F. Fallside, 1991.
- Deep Representation Learning in Speech Processing, Challenges, Recent Advances, and Future Trends, Siddique Latif, Rajib Rana, Sara Khalifa, Raja Jurdak, Junaid Qadir and Bjorn W. Schuller, 2021.
- Гольдберг Й., Нейросетевые методы в обработке естественного языка, пер. с англ. А. А. Слинкина. – М.: ДМК Пресс, 2019.
- Mean Field Theory for Sigmoid Belief Networks, L. K. Saul, T. Jaakkola, M. I. Jordan, 1996.
- Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review, Waseem Rawat, Zenghui Wang, 2017.
- The “echo state” approach to analysing and training recurrent neural networks – with an Erratum note, Herbert Jaeger, 2010.
- Deep belief networks, Geoffrey E. Hinton, 2009.
- High Performance Convolutional Neural Networks for Document Processing, Kumar Chellapilla, Sidd Puri, Patrice Y. Simard, 2006.
- Deep Boltzmann Machines, Ruslan Salakhutdinov, Geoffrey Hinton, 2009.
- Optimized deep belief networks on CUDA GPUs, Teng Li ..., 2015.
- Deep learning with COTS HPC systems, Adam Coates, Brody Huval, Tao Wang, David J., Andrew Y. Ng, Bryan Catanzaro.
- Deep Big Multilayer Perceptrons for Digit Recognition, D. Ciresan, U. Meier, L. Gambardella, J. Schmidhuber, 2011.
- An Analysis of Single-Layer Networks in Unsupervised Feature Learning, Adam Coates, A. Ng, Honglak Lee, 2011.
- Глубокое обучение, Николенко С., Кадури А., Архангельская Е. СПб., Питер, 2018.

- ImageNet classification with deep convolutional neural networks, A. Krizhevsky, I. Sutskever, Geoffrey E. Hinton, 2012.
- Deep learning with COTS HPC systems, Adam Coates, Brody Huval, Tao Wang, David J. Wu, Bryan Catanzaro, A. Ng, 2013.
- Саймон Хайкин, Нейронные сети, полный курс, второе издание, Москва, Санкт-Петербург-Киев, 2006.
- <https://vc.ru/u/1216053-nftishka/605828-top-40-luchshih-neirosetei-dlya-kazhdogo-luchshie-neiroseti-dlya-zarabotka>
- <https://trendo.me/blog/podborka-poleznih-v-rabote-servisov-na-osnove-iskusstvennogo-intellekta/>
- <https://skyeng.ru/magazine/obzor-luchshih-nejrosetej-dlya-vseh-zadach/>
- <https://journal.tinkoff.ru/short/ai-for-all/>
- <https://smmplanner.com/blog/top-nieirosietiei-dlia-raboty-s-kontientom-v-etom-ghodu/>
- <http://iitp.ru/upload/publications/6256/vyugin1.pdf>
- <http://www.ievbras.ru/ecostat/Kiril/Library/Book1/Content394/Content394.htm>
- <https://habr.com/ru/articles/214317/>
- <https://www.mql5.com/ru/articles/8908>
- <https://books.google.by/books?id=-ThwEAAAQBAJ&pg=PA104&lpg=PA104&dq=%D0%BC%D0%BD%D0%BE%D0%B3%D0%BE%D1%81%D0%BB%D0%BE%D0%B9%D0%BD%D1%8B%D0%B9+%D0%BF%D0%B5%D1%80%D1%81%D0%B5%D0%BF%D1%82%D1%80%D0%BE%D0%BD&source=bl&ots=q35B168pW3&sig=ACfU3U0DvHbph9keNpOnN8bCP0x8N3pMPA&hl=ru&sa=X&ved=2ahUKEwjdk-DZr7OGAxVFIxAIHeTTAew4FBD0AXoECAMQAg#v=onepage&q=%D0%BC%D0%BD%D0%BE%D0%B3%D0%BE%D1%81%D0%BB%D0%BE>

%D0%B9%D0%BD%D1%8B%D0%B9%20%D0%BF%D0%B5%D1%80%D1%81
%D0%B5%D0%BF%D1%82%D1%80%D0%BE%D0%BD&f=false

- <https://intuit.ru/studies/courses/2265/243/lecture/6249?page=2>
- <https://skillbox.ru/media/code/kak-ustroeno-mashinnoe-obuchenie-zadachi-algoritmy-i-vidy-machine-learning/>
- https://znaniy.ru/articles/%D0%9C%D0%B0%D1%88%D0%B8%D0%BD%D0%BD%D0%BE%D0%B5_%D0%BE%D0%B1%D1%83%D1%87%D0%B5%D0%BD%D0%B8%D0%B5
- https://nbpublish.com/library_read_article.php?id=13730
- <https://cloud.vk.com/blog/what-is-machine-learning>
- <https://proglab.io/p/kak-lineynaya-algebra-ispolzuetsya-v-mashinnom-obuchanii-2021-02-17>
- <https://training.by/ru/blog/555>
- <https://wadline.ru/matematika-i-machine-learning-dlya-data-science>
- <https://tproger.ru/translations/math-for-ai-linear-algebra>
- <https://www.labirint.ru/books/963342/>
- <https://scilead.ru/article/4528-teoriya-veroyatnosti-v-programmirovanii>
- <https://cyberleninka.ru/article/n/bayesovskiy-klassifikator-v-mashinnom-obuchanii-viewer>
- <https://cyberleninka.ru/article/n/osnovy-differentsialnogo-ischisleniya-i-ego-primeneniye>
- https://dspace.spbu.ru/bitstream/11701/32448/1/VKR_final__1_.pdf
- https://www.mi-ras.ru/noc/17_18/shamin.pdf

- <https://azure.microsoft.com/ru-ru/resources/cloud-computing-dictionary/what-are-machine-learning-algorithms>
- <https://bigdataschool.ru/blog/graphs-for-ml-models-enrichment-airbnb-case.html>
- <https://stepik.org/lesson/387091/step/1?unit=539654>
- <http://www.machinelearning.ru/wiki/images/6/6d/voron-ml-1.pdf>
- <https://otus.ru/nest/post/1263/>
- <https://blog.ycla.ai/raznovidnosti-nejrosetej/>
- <https://gb.ru/blog/neironnye-seti/>
- <https://qna.habr.com/q/363233>
- <https://uchet-jkh.ru/i/na-cem-rabotayut-neiroseti-osnovnye-platformy-i-instrumenty/>
- https://dzen.ru/a/ZPHDg7c8jSZx141_?utm_referrer=www.google.com&is_autologin_ya=true
- <https://adpass.ru/sposoby-i-metody-mashinnogo-obucheniya-2/>
- <https://habr.com/ru/amp/publications/427867/>
- <https://cloud.ru/ru/blog/ml-bez-uchitelya>
- <https://jobs.teamnety.com/jobs/details/48742?lang=ua>
- <https://proglib.io/p/chto-takoe-obuchenie-s-podkrepleniem-i-kak-ono-rabotaet-obyasnyаем-na-prostyh-primerah/amp/>
- <https://habr.com/ru/amp/publications/485228/>
- <https://itglobal.com/ru-by/company/blog/metody-mashinnogo-obucheniya/>
- <https://habr.com/ru/amp/publications/322370/>
- <https://medium.com/phygitalism/%D0%BA%D0%B0%D0%BA-%D0%B5%D1%89%D0%B5-%D0%B3%D0%B5%D0%BD%D0%B5%D1%82%D0%B8%D1%87%D0%B5%D1%81%D0%>

BA%D0%B8%D0%B5-%D0%B0%D0%BB%D0%B3%D0%-

BE%D1%80%D0%B8%D1%82%D0%BC%D1%8B-

%D0%BC%D0%BE%D0%B3%D1%83%D1%82-%D0%BF%D0%BE%D0%BC%


D0%BE%D1%87%D1%8C-%D0%B3%D0%BB%D1%83%D0%B1%D0%BE%D0

%BA%D0%BE%D0%BC%D1%83-%D0%BE%D0%B1%D1%83%D1%87%D0%

B5%D0%BD%D0%B8%D1%8E-7fdcf2a44cc4

- https://ru.wikipedia.org/wiki/%D0%9C%D0%B5%D1%82%D0%BE%D0%B4_%D0%BE%D0%B1%D1%80%D0%B0%D1%82%D0%BD%D0%BE%D0%B3%D0%BE_%D1%80%D0%B0%D1%81%D0%BF%D1%80%D0%BE%D1%81%D1%82%D1%80%D0%B0%D0%BD%D0%B5%D0%BD%D0%B8%D1%8F_%D0%BE%D1%88%D0%B8%D0%B1%D0%BA%D0%B8
- https://neerc.ifmo.ru/wiki/index.php?title=%D0%9E%D0%B1%D1%80%D0%B0%D1%82%D0%BD%D0%BE%D0%B5_%D1%80%D0%B0%D1%81%D0%BF%D1%80%D0%BE%D1%81%D1%82%D1%80%D0%B0%D0%BD%D0%B5%D0%B%D0%B8%D0%B5_%D0%BE%D1%88%D0%B8%D0%B1%D0%BA%D0%B8
- <https://otus.ru/nest/post/1592/>
- <https://microtechnics.ru/obuchenie-nejronnyh-setej-obratnoe-rasprostranenie-oshibki/>
- <https://habr.com/ru/amp/publications/571296/>
- <http://robotrends.ru/robopedia/kognitivnye-sposobnosti>
- <http://www.machinelearning.ru/wiki/images/6/6d/voron-ml-1.pdf>
- https://zhps.ejournal.by/jour/article/view/1307?locale=ru_RU
- <https://merehead.com/ru/amp/blog/machine-learning-trends-in-2022/>
- <https://ceur-ws.org/Vol-11108/paper1.pdf>
- <https://app.leonardo.ai/personal-feed>
- <https://ideogram.ai/t/top/1>

- <https://m.seonews.ru/glossary/captcha/>
- shedevrum.ai/kuliko-irina@yandex.by
- https://libeldoc.bsuir.by/bitstream/123456789/39033/1/Prokopenya_Svertochnyye.pdf
- https://ai-news.ru/2021/01/glubokie_nejronnye_seti_puti_primeneniya.html
- <https://practicum.yandex.ru/blog/chto-takoe-kompyuternoe-zrenie/>
- https://ru.freepik.com/icon/algorithm_10700718#fromView=keyword&page=1&position=34&uuid=517e5c06-0f4f-4853-8a89-c60dc67cb3e0





Издательство «Наука и Техника» выпускает книги более 25 лет!

Уважаемые авторы!

Приглашаем к сотрудничеству по созданию книг
по **IT-технологиям, электронике, электротехнике, медицине, педагогике.**

Наши преимущества:

- являемся одним из ведущих технических издательств страны;
- выпускаем книги большими тиражами, что положительно влияет на гонорар авторов;
- регулярно переиздаем тиражи, автоматически выплачивая гонорар за *каждый* тираж;
- применяем индивидуальный подход в работе с каждым автором;
- работаем профессионально: от корректуры до авторских дизайн-проектов;
- проводим политику доступной цены;
- имеем собственные каналы сбыта: от федеральных сетей, крупнейших книжных магазинов РФ, ведущих маркетплейсов ОЗОН, Wildberries, Яндекс-Маркет и др. до ведущих библиотек вузов, ссузов.

Ждем Ваши предложения:

- тел. **(812) 412-70-26**
- эл. почта: **nitmail@nit.com.ru**

Будем рады сотрудничеству!

Для заказа книг:

➤ интернет-магазин: nit.com.ru

- более 3000 пунктов выдачи на территории РФ, доставка 3–5 дней
- более 300 пунктов выдачи в Санкт-Петербурге и Москве, доставка 1–2 дня
- тел. **(812) 412-70-26**
- эл. почта nitmail@nit.com.ru

➤ магазин издательства: г. Санкт-Петербург, пр. Обуховской обороны, д. 107

- метро Елизаровская, 200 м за ДК им. Крупской
- ежедневно с 10.00 до 18.00
- справки и заказ: тел. **(812) 412-70-26**

➤ книжные сети и магазины

- | | |
|---|-------------------------|
| • «Читай-город» - сеть магазинов | тел. +7 (495) 424-84-44 |
| • «Буквоед» - сеть магазинов | тел. +7 (812) 601-0-601 |
| • Московский дом книги – сеть магазинов | тел. +7 (495) 789-35-91 |
| • ТД «БиблиоГлобус» | тел. +7 (495) 781-19-12 |
| • «Амитель» — сеть магазинов | тел. +7 (473) 223-00-02 |
| • Дом книги, г. Екатеринбург | тел. +7 (343) 289-40-45 |
| • Дом книги, г. Нижний Новгород | тел. +7 (831) 246-22-92 |
| • Приморский торговый Дом книги | тел. +7 (423) 263-10-54 |

➤ маркетплейсы ОЗОН, Wildberries, Яндекс-Маркет, Myshop и др.

Куликова И. В.

Нейросети на Python

Основы ИИ и машинного обучения

Группа подготовки издания:

Зав. редакцией компьютерной литературы: *Е.В. Финков*

Редактор: *Н.В. Жерлов*

Корректор: *А.В. Громова*

Изображения в книге использованы с ресурсов freepik.com и vecteezy.com

12+

ООО "Издательство Наука и Техника"

ОГРН 1217800116247, ИНН 7811763020, КПП 781101001

192029, г. Санкт-Петербург, пр. Обуховской обороны, д. 107, лит. Б, пом. 1-Н

Подписано в печать 28.06.2024. Формат 70х100 1/16.

Бумага офсетная. Печать офсетная. Объем 19 п.л.

Тираж 2000. Заказ 10014.

Отпечатано с готового оригинал-макета

ООО «Принт-М», 142300, М.О., г.Чехов, ул. Полиграфистов, д.1

Нейросети на Python

Основы ИИ и машинного обучения

Эта книга является практическим комплексным гидом по изучению ИИ и применению нейросетей. В ней вы найдете информацию о различных типах нейросетей, их архитектуре, принципах работы и различных возможностях использования.

Примеры использования библиотек NumPy, PyTorch, Matplotlib, SciPy, NetworkX, TensorFlow, OpenCV, Pandas, scikit-learn, nltk помогут вам лучше понять действия нейросети в реальных условиях.

Математические основы машинного обучения, с многочисленными примерами уравнений и формул на языке программирования Python, помогут понять истоки появления нейросетей с научной точки зрения.


Отдельно рассмотрено практическое применение искусственного интеллекта, описаны способы взаимодействия с нейросетями разной направленности. Это будет полезно для всех тех, кто желает овладеть многочисленными возможностями современных нейросетей: генерацией изображений, созданием видео, написанием текстов, созданием озвучки и т.д.

Помимо теоретической и практической частей, в книге есть ссылки на реальные нейросети, которые помогут читателям углубить свои знания и навыки в области их практического использования.

издательство

НАУКА и ТЕХНИКА

рекомендует



ISBN 978-5-907592-55-1



9 785907 592551 >

«Издательство Наука и Техника» г. Санкт-Петербург
Для заказа книг: т. (812) 412-70-26

E-mail: nitmail@nit.com.ru

Сайт: nit.com.ru

