

ТЕКСТОВАЯ МАГИЯ: КАК НЕЙРОСЕТИ
ТРАНСФОРМИРУЮТ ОБРАБОТКУ ЕСТЕСТВЕННОГО
ЯЗЫКА

НЕЙРОСЕТИ

ОБРАБОТКА ЕСТЕСТВЕННОГО ЯЗЫКА



ДЖЕЙД КАРТЕР

Джейд Картер
**Нейросети. Обработка
естественного языка**
Серия «Нейросети», книга 3

*http://www.litres.ru/pages/biblio_book/?art=69735148
SelfPub; 2023*

Аннотация

Книга представляет собой исчерпывающее руководство по применению нейросетей в различных областях анализа текста. С этой книгой читатели отправятся в увлекательное путешествие по миру искусственного интеллекта, где они узнают о бесконечных возможностях, которые предоставляют нейронные сети.

Содержание

Введение	4
Глава 1: Введение в обработку естественного языка и нейросети	6
Глава 2: Основы нейронных сетей для NLP	23
Конец ознакомительного фрагмента.	90

Джейд Картер

Нейросети. Обработка естественного языка

Введение

В мире, где информация преобразуется в валовый объем текстов, обработка естественного языка (NLP) стала неотъемлемой частью нашего повседневного взаимодействия. От переписки в социальных сетях до поиска информации в сети, от автоматизированных ассистентов до перевода на другие языки, обработка текста стала не просто инструментом, а неотъемлемой частью современной культуры и бизнеса.

Все это стало возможным благодаря нейросетям – мощному инструменту искусственного интеллекта, способному анализировать, понимать и генерировать текст с удивительной точностью. Нейронные сети обрели огромное значение для обработки естественного языка, взлетев на вершину развития в этой области.

Эта книга – не просто техническое руководство, но и увлекательное путешествие в мир текста, смысла и их интерпретации с помощью нейронных сетей.

Мы погрузимся в архитектуры нейросетей, их сложности

и возможности. Мы разберемся, как слова превращаются в вектора, как алгоритмы способны понимать тональность текста и даже создавать свой собственный контент. Мы рассмотрим задачи машинного перевода, сентимент-анализа, генерации текста и вопросно-ответных систем – все с применением мощи нейросетей.

Книга также обратит внимание на важные этические и социальные вопросы, связанные с использованием нейросетей в анализе текста. Мы поговорим о справедливости, предвзятости и том, как обеспечить, чтобы NLP приносила пользу всему обществу.

Вы окунетесь в мир текстов, алгоритмов и искусства обработки информации. Вас ждет увлекательное путешествие от основ до передовых методов, от технических деталей до широких перспектив. Добро пожаловать в мир нейросетей и языка!

Глава 1: Введение в обработку естественного языка и нейросети

Определение обработки естественного языка (NLP) и её важность

Обработка естественного языка (NLP-Natural Language Processing) – это область искусственного интеллекта, которая занимается разработкой методов и алгоритмов для анализа, понимания, интерпретации и взаимодействия с естественным языком, на котором общается человек. Эта область стремится дать компьютерам способность работать с текстами так же, как это делают люди, с учетом контекста, смысла и тонких нюансов языка.

Важность NLP стала несомненной в современном мире, где текстовая информация играет ключевую роль во многих аспектах жизни. Рассмотрим некоторые из аспектов, подчеркивающие важность обработки естественного языка:

1. Коммуникация с компьютерами:

Обработка естественного языка (NLP) играет революционную роль в том, как люди взаимодействуют с компьютерами и технологией в целом. Интерфейсы взаимодействия между человеком и компьютером часто требовали технической экспертизы или знаний, чтобы эффективно использовать их. Однако NLP меняет этот подход, предоставляя ин-

туитивный и естественный способ взаимодействия.

До появления NLP, пользователи обычно должны были обучаться специальным командам, синтаксису и интерфейсам, чтобы взаимодействовать с программами и системами. Это создавало барьер для вовлечения не-технических пользователей и замедляло внедрение технологий в разные сферы жизни.

NLP позволяет преодолеть этот барьер, предоставляя возможность вводить команды и запросы на естественном языке, таком, как мы общаемся на повседневном уровне. Это означает, что даже те, кто не обладает техническими навыками, могут легко использовать компьютеры, телефоны, устройства умного дома и другие технологии.

Примеры использования включают:

– Виртуальные ассистенты: Сегодняшние виртуальные ассистенты, такие как Siri, Google Assistant и Amazon Alexa, позволяют пользователям задавать вопросы, давать команды и получать информацию с помощью своего естественного голоса. Это значительно упрощает взаимодействие с устройствами и выполняемыми ими задачами.

– Поиск и навигация: Системы NLP позволяют пользователям задавать поисковые запросы в свободной форме, и компьютеры могут интерпретировать их смысл и предоставлять соответствующие результаты. Это делает процесс поиска информации более естественным и удобным.

– Команды умного дома: Устройства умного дома, такие

как умные колонки и термостаты, позволяют пользователям управлять своим окружением с помощью голосовых команд. Это делает домашнюю автоматизацию более доступной.

Кратко говоря, NLP делает технологии более интуитивными и доступными, позволяя людям взаимодействовать с компьютерами так, как они общаются друг с другом. Это устраняет барьеры в использовании технологий и делает их доступными для широкой аудитории, способствуя повсеместному внедрению инноваций.

2. Интернет и поиск информации:

Большая часть информации в современном мире находится в текстовом формате и представлена в сети Интернет. Это может быть новостной контент, статьи, блоги, обзоры, описания товаров, комментарии и многое другое. Однако доступ к этой огромной информационной базе не всегда простой задачей. И вот здесь вступает в игру обработка естественного языка (NLP), делая доступ к знаниям и информации более эффективным и удобным.

Подходы NLP изменяют способ, которым мы можем искать, фильтровать и агрегировать информацию в Интернете:

– Более точные поисковые системы. Традиционные поисковые системы, хотя и предоставляют результаты, все же могут быть не всегда точными. С помощью NLP поисковые запросы становятся более контекстуальными и понятными для машин, что позволяет предоставлять более релевантные и точные результаты.

– Поиск семантически связанных данных. NLP способствует пониманию связей между словами и концепциями. Это позволяет системам более точно понимать запросы пользователя и находить материалы, связанные не только по ключевым словам, но и по контексту и смыслу.

– Агрегаторы новостей и обзоров. NLP может считывать и обрабатывать огромное количество новостей и статей, выделяя ключевую информацию и предоставляя сводки или краткие обзоры. Это позволяет людям быстро ознакомиться с событиями и трендами, даже если времени на чтение длинных текстов ограничено.

– Поиск в больших объемах текстов. В корпоративной среде, аналитика и поиск информации могут быть критически важными задачами. NLP позволяет автоматически обрабатывать и анализировать большие объемы текстов, что упрощает нахождение необходимой информации.

– Анализ мнений и отзывов. Большое количество отзывов и комментариев находится в текстовом формате. NLP помогает автоматически анализировать этот контент, выделяя сентимент, тенденции и важные моменты, что может быть полезно для бизнеса и маркетинга.

NLP играет ключевую роль в улучшении способов доступа к информации в интернете. Это делает процесс поиска и агрегации информации более удобным, эффективным и интеллектуально обогащенным, что в итоге повышает качество взаимодействия человека с информационными ресурсами.

3. Машинный перевод:

В современном мире, где международные связи становятся все более плотными, свободный обмен информацией между разными культурами и на разных языках становится ключевой задачей. Однако различия в языках могут создавать языковой барьер, затрудняя понимание и коммуникацию между людьми разных национальностей.

В этом контексте обработка естественного языка (NLP) выходит на передний план как технология, способствующая разрыву этого барьера и стимулирующая межкультурный обмен. Автоматические системы машинного перевода, разрабатываемые с использованием NLP, способны переводить тексты с одного языка на другой, сохраняя смысл и контекст. Прогресс в области машинного перевода, такие как технология трансформеров, позволяют создавать более точные и естественные переводы, уменьшая языковой барьер между людьми.

Кроме того, компании и разработчики могут использовать NLP для адаптации своего контента и продуктов к разным языкам и культурам. Это важно не только для внешней коммуникации, но и для предоставления качественного опыта пользователя в разных частях мира.

Развитие технологий NLP и компьютерного зрения позволяет создавать мультимодальные переводчики, которые способны переводить не только текст, но и изображения, звуковые сигналы и видео. Это улучшает возможности взаимо-

действия между людьми, говорящими на разных языках.

Наконец, NLP играет важную роль в образовательных проектах и культурном обмене. Платформы для онлайн-курсов и образовательных ресурсов могут использовать машинный перевод для расширения своей аудитории и достижения учащихся из разных стран.

В итоге, благодаря технологиям NLP и автоматическим системам машинного перевода, языковой барьер уменьшается, что способствует свободному обмену идеями, культурой, знанием и информацией между разными культурами. Это поднимает культурный обмен на новый уровень, делая его более доступным, интересным и важным для общества в целом.

4. Анализ тональности и настроений:

Понимание тональности текста – это существенный аспект для различных сфер деятельности, таких как бизнес, социальные медиа и маркетинг. Нейронные сети и методы обработки естественного языка (NLP) играют важную роль в этом процессе, позволяя автоматически анализировать отзывы, комментарии и обсуждения, что в свою очередь помогает оценивать общественное мнение и восприятие.

Бизнес и маркетинг используют анализ тональности текстов для оценки реакции клиентов на продукты и услуги. Автоматическая обработка большого объема отзывов и комментариев позволяет компаниям более точно понимать, как их продукты оцениваются клиентами. Это может помочь в

улучшении качества продукции, а также в адаптации маркетинговых стратегий.

Социальные медиа являются ещё одной областью, где анализ тональности текста имеет большое значение. Бренды, знаменитости и обычные пользователи активно общаются в социальных сетях, оставляя комментарии, рецензии и отзывы. Автоматический анализ помогает определить, как публика реагирует на конкретные события, новости или продукты, что позволяет принимать более информированные решения.

Более того, анализ тональности текста может быть использован для мониторинга общественного мнения и предсказания трендов. Это может быть полезно для прогнозирования изменений на рынке, выявления возможных кризисов и понимания общественных настроений.

Суммируя, NLP открывает перед бизнесом, социальными медиа и маркетингом новые возможности для более глубокого и точного анализа текстов и определения их тональности. Это позволяет более эффективно взаимодействовать с аудиторией, улучшать продукты и услуги, а также более четко выстраивать стратегии на основе общественных реакций.

5. Генерация контента:

Обработка естественного языка (NLP) стала неотъемлемой частью современных технологий, позволяя автоматизировать и упростить создание текстового контента во многих областях. Этот аспект особенно интересен в сферах, где тре-

буется большой объем текста, начиная от новостных публикаций и заканчивая креативными проектами.

Автоматическая генерация новостей и статей.

С помощью NLP возможно создание текстовых статей и новостных сообщений без необходимости полного участия человека. Нейронные сети могут анализировать большие объемы данных, извлекать ключевые факты и события, а затем формировать их в структурированный и читаемый текст. Это может быть полезно, например, для автоматического генерирования финансовых отчетов, спортивных новостей или погодных прогнозов.

Создание контента для маркетинга.

NLP позволяет создавать тексты для маркетинговых материалов, таких как рекламные слоганы, описания продуктов, блог-посты и рассылки. С помощью алгоритмов NLP можно создавать контент, который затрагивает интересы целевой аудитории, делая маркетинг более персонализированным и эффективным.

Креативные проекты и искусство.

NLP может быть использовано для создания художественных текстов, стихотворений, историй и даже музыкальных текстов. Нейросети могут анализировать структуры и стили различных авторов, а затем генерировать тексты в подобных стилях. Это открывает двери для новых форм искусства и экспериментов с креативными идеями.

Создание контента для социальных медиа.

Автоматически сгенерированный контент может быть использован для заполнения социальных медиа-профилей компаний, публикации регулярных обновлений или даже создания мемов и смешных картинок с подписями.

Важно отметить, что хотя NLP дает возможность автоматически создавать текстовый контент, человеческое вмешательство и контроль могут оставаться необходимыми. Помимо творческих проектов, алгоритмы NLP могут использоваться для предварительной генерации текстов, которые затем могут быть доработаны и отредактированы специалистами в соответствии с конкретными целями и стандартами.

6. Медицинская диагностика и исследования:

Обработка естественного языка (NLP) играет существенную роль в области здравоохранения, где большие объемы медицинских текстов требуют детального анализа и интерпретации. Эта технология применяется для обработки медицинских записей, статей, клинических исследований и других текстовых данных, что влияет на улучшение диагностики и научных исследований в медицине.

Автоматическая обработка медицинских текстов с помощью NLP позволяет:

– Извлекать информацию из медицинских записей: Медицинские данные, такие как истории болезни, результаты тестов и отчеты о лечении, часто представлены в текстовой форме. NLP позволяет автоматически извлекать важные медицинские факты и события из этих записей, что помогает

врачам и исследователям быстрее обнаруживать паттерны и изменения в здоровье пациентов.

– Поддерживать клинические исследования: В больших масштабах клинических исследований сбор и анализ данных может быть огромной задачей. NLP может помочь автоматизировать процессы обработки текстовых данных, ускоряя анализ и выявление статистически значимых результатов.

– Улучшать точность диагностики: NLP способствует анализу большого объема медицинских публикаций и исследований, что позволяет врачам получать обновленную информацию о симптомах, лечении и прогнозах различных заболеваний. Это может повысить качество диагностики и выбора оптимальных методов лечения.

– Мониторинг здоровья пациентов: NLP может быть использовано для анализа текстовых данных, собранных от пациентов через вопросники или онлайн-журналы здоровья. Это позволяет врачам исследовать долгосрочные тенденции в здоровье и реагировать на них.

– Оптимизировать медицинскую документацию: В больницах и клиниках медицинская документация может быть объемной и сложной. NLP может использоваться для автоматической категоризации и аннотации медицинских записей, что улучшает



организацию и доступ к данным.

7. Именованные сущности (NER):

Задача извлечения именованных сущностей (NER) в обработке естественного языка (NLP) является фундаментальной и важной частью многих приложений, связанных с анализом текстовых данных. В этой задаче нейронные сети выявляют и классифицируют именованные сущности в тексте, что позволяет извлекать структурированную информацию из неструктурированных текстов. Вот более подробное объяснение этой задачи:

Что такое именованные сущности (NER)?

Именованные сущности – это конкретные слова или фразы в тексте, которые представляют собой уникальные имена или метки. Эти имена могут включать в себя:

- Имена людей: Например, "Джон Смит".
- Названия организаций: Например, "Google" или "Международный Красный Крест".
- Местоположения: Например, "Париж" или "Миссисипи".
- Даты: Например, "10 марта 1990 года".
- Валюты: Например, "\$100" или "1,000 евро".
- Проценты: Например, "20%" или "50 процентов".
- Ключевые события: Например, "Вторая мировая война".
- Продукты и бренды: Например, "iPhone" или "Coca-Cola".

Извлечение именованных сущностей имеет большое зна-

чение для разных задач NLP и информационного поиска:

Структурированная информация: Позволяет преобразовать неструктурированный текст в структурированные данные, что облегчает поиск и анализ информации.

Информационный поиск: Улучшает качество поисковых систем, позволяя точнее находить источники или документы, содержащие конкретные именованные сущности.

Анализ социальных медиа: Помогает в анализе обсуждений организаций, событий и персон в социальных сетях.

Автоматическое создание баз данных: Позволяет автоматически заполнять базы данных или справочники данными из текстовых источников.

Именованные сущности – это ключевой элемент для понимания и анализа текстовых данных, и их извлечение с помощью нейросетей существенно улучшает возможности автоматической обработки текста в различных областях, включая информационный поиск, анализ социальных медиа и автоматическое создание баз данных.

8. Автоматическая суммаризация:

Автоматическая суммаризация – это задача, в которой нейросети могут создавать краткие и информативные резюме больших текстовых документов. Этот процесс позволяет выделить наиболее важные и значимые аспекты текста, удалив при этом избыточную или менее важную информацию. Автоматическая суммаризация имеет ряд важных применений:

1. **Обзоры новостей:** Новостные агентства и интернет-платформы могут использовать автоматическую суммаризацию, чтобы предоставлять читателям краткие обзоры главных событий и новостей из различных источников.

2. **Анализ научных статей:** Исследователи и ученые могут использовать автоматическую суммаризацию для быстрого изучения содержания научных статей и исследований, что помогает в научной работе и литературном обзоре.

3. **Извлечение ключевых моментов из текста:** Автоматическая суммаризация может быть полезной для выявления ключевых фактов, событий или информации из текста, что упрощает принятие решений и анализ текстовых данных.

Использование нейросетей для автоматической суммаризации позволяет создавать более точные и информативные краткие версии текста, что может быть очень полезно в областях, где требуется обработка и анализ больших объемов текстовой информации.

9. Чат-боты:

Чат-боты – это компьютерные программы, которые разработаны для автоматического взаимодействия с пользователями на естественном языке. Они могут выполнять разнообразные задачи, от ответов на часто задаваемые вопросы до выполнения более сложных функций, таких как заказ продуктов или бронирование билетов. Нейронные сети играют ключевую роль в разработке и функционировании чат-ботов. Рассмотрим подробнее об их применении:

1. Архитектуры нейронных сетей в чат-ботах**:

– Рекуррентные нейронные сети (RNN): RNN часто используются в чат-ботах для обработки последовательности вопросов и ответов. Они могут хранить контекст предыдущих вопросов и использовать этот контекст для формирования более информативных ответов.

– Сверточные нейронные сети (CNN): CNN могут использоваться для обработки текста, выявления ключевых фраз и выделения важных элементов в тексте.

– Трансформеры, такие как BERT или GPT, стали популярными в чат-ботах благодаря своей способности учитывать контекст и генерировать более человекоподобные ответы.

2. Обучение нейронных сетей для чат-ботов:

– Обучение с учителем: В некоторых случаях чат-боты могут быть обучены на большом корпусе чатов с людьми, чтобы научиться отвечать на типичные вопросы и запросы. Этот метод требует большого объема данных и времени на обучение.

– Обучение с подкреплением: В других случаях чат-боты могут использовать метод обучения с подкреплением, где они получают обратную связь от пользователей и настраивают свои ответы на основе успешных взаимодействий.

3. Применение чат-ботов

– Обслуживание клиентов: Чат-боты часто используются компаниями для предоставления быстрого и эффективного

обслуживания клиентов, отвечая на вопросы, уточняя информацию о продуктах и услугах, а также решая проблемы клиентов.

– **Онлайн-торговля:** Чат-боты могут помочь пользователям выбрать продукты, советовать товары и даже обрабатывать заказы и платежи.

– **Образование и консультирование:** В образовании и консультационных услугах чат-боты могут предоставлять информацию, решать задачи и помогать в обучении.

– **Развлечения и развлекательные приложения:** Чат-боты используются в играх и развлекательных приложениях для взаимодействия с пользователем и создания интересного контента.

– **Системы управления:** Чат-боты также используются для управления умными домами, заказа такси, бронирования билетов и других задач автоматизации.

Чат-боты, поддерживаемые нейронными сетями, стали важной частью многих сфер бизнеса и обслуживания клиентов. Они позволяют компаниям автоматизировать часть обслуживания и улучшить взаимодействие с пользователями, обеспечивая более быстрый и эффективный способ получения информации и решения задач.

Таким образом, NLP играет важную роль в улучшении диагностики, исследований и общей эффективности здравоохранения, помогая обрабатывать и анализировать огромные объемы медицинских текстовых данных.

В этой книге мы будем исследовать, как нейронные сети, являющиеся одной из самых мощных и актуальных технологий искусственного интеллекта, применяются для решения задач обработки естественного языка. Наше путешествие начнется с основ, и мы увидим, как эти нейросети способны преобразовать текст в понимание, анализ и даже творчество.

Глава 2: Основы нейронных сетей для NLP

2.1. Обзор архитектур нейросетей, применяемых в NLP, включая рекуррентные и сверточные модели

Обработка естественного языка (NLP) представляет собой широкую область, где нейронные сети добились значительных успехов. В NLP используются разнообразные архитектуры нейросетей, которые позволяют обрабатывать текстовую информацию. Давайте рассмотрим две основные архитектуры: рекуррентные нейронные сети (RNN) и сверточные нейронные сети (CNN).

Рекуррентные нейронные сети (RNN)

RNN представляют собой мощный класс архитектур, разработанный для обработки последовательных данных, таких как текст, временные ряды и аудиосигналы. Основная особенность RNN заключается в том, что они обладают обратными связями, которые позволяют информации из предыдущих шагов влиять на текущие вычисления. Это делает RNN особенно подходящими для задач, где важен контекст и зависимость между данными в разных частях последователь-

ности.

Основные компоненты RNN включают в себя:

1. Скрытое состояние (Hidden State): Скрытое состояние является одной из ключевых концепций в рекуррентных нейронных сетях (RNN). Оно представляет собой внутреннее состояние сети, которое аккумулирует информацию о предыдущих элементах в последовательности. Давайте подробнее рассмотрим этот концепт:

– Основное предназначение:

Скрытое состояние в RNN служит для сохранения и передачи информации о контексте последовательности данных. Каждый элемент (например, слово в тексте) последовательности влияет на состояние сети, и это состояние обновляется с каждым новым элементом. Таким образом, скрытое состояние может содержать информацию о том, что произошло в прошлом, и влиять на то, как будет обработан следующий элемент.

– Функция скрытого состояния:

Скрытое состояние RNN можно представить как вектор, который хранит информацию, актуальную на текущем этапе обработки последовательности. Этот вектор может включать в себя разнообразную информацию, в зависимости от конкретной задачи:

*История: Скрытое состояние может содержать информацию о предыдущих элементах последовательности, что делает его способным сохранять контекст.

*Зависимости: Состояние может отражать зависимости и взаимосвязи между элементами последовательности, например, какие слова в тексте связаны между собой.

*Контекст: В зависимости от задачи, скрытое состояние может содержать контекстную информацию, такую как смысл предложения или текста.

– Обновление скрытого состояния:

Обновление скрытого состояния происходит на каждом шаге обработки элемента последовательности. Это обновление определяется архитектурой сети и весами, которые подбираются в процессе обучения.

– Использование скрытого состояния:

Скрытое состояние может использоваться в различных задачах. Например, в задаче машинного перевода, скрытое состояние может содержать информацию о предыдущих словах в исходном предложении и влиять на выбор следующего слова в переводе. В анализе тональности текста, скрытое состояние может представлять собой агрегированную информацию о предыдущих словах и помогать определить общий тон текста.

– Проблема затухания градиентов:

Важно отметить, что у классических RNN есть проблема затухания градиентов, которая может привести к утере информации о более давних элементах последовательности. Это ограничение привело к разработке более сложных архитектур RNN, таких как LSTM и GRU, которые способны эф-

фективнее работать с долгосрочными зависимостями в данных.

Скрытое состояние в RNN играет важную роль в обработке последовательных данных и позволяет сетям учитывать контекст и зависимости между элементами в последовательности. Различные модификации RNN, такие как LSTM и GRU, были разработаны для устранения ограничений и улучшения способности моделей к обработке более долгих и сложных последовательностей.

Для наглядного представления скрытого состояния в рекуррентных нейронных сетях (RNN), давайте представим ситуацию, связанную с обработкой текстовых данных, чтобы понять, как это работает.

Представьте, что у нас есть следующее предложение: "Сегодняшняя погода очень хорошая." Мы хотим использовать RNN для анализа тональности этого предложения и определения, положительное оно или отрицательное.

1. Инициализация скрытого состояния:

На первом шаге обработки этого предложения скрытое состояние инициализируется некоторым начальным значением, например, нулевым вектором. Это начальное состояние несет в себе информацию о предыдущих шагах, но на этом этапе оно пустое.

2. Обработка слов поочередно:

Теперь мы начинаем обрабатывать слова в предложении поочередно, шаг за шагом. Для каждого слова RNN обновля-

ет свое скрытое состояние, учитывая информацию о предыдущих словах и текущем слове. На этом этапе RNN может учитывать, что "Сегодняшняя" и "погода" идут перед "очень" и "хорошая", и что они могут влиять на общий смысл предложения.

3. Агрегация информации:

После обработки всех слов в предложении скрытое состояние будет содержать информацию, учитывающую контекст всего предложения. Это состояние может отражать, что весь контекст в данном предложении указывает на положительную тональность.

4. Выдача результата:

Наконец, RNN может использовать это скрытое состояние для определения тональности предложения, и, например, классифицировать его как "положительное".

Исходное состояние скрытого состояния (шаг 1) и его изменение по мере обработки каждого слова (шаги 2 и 3) – это ключевые элементы работы RNN в обработке текстовых данных. Это позволяет модели учитывать зависимости между словами и контекст, что делает RNN мощными инструментами в NLP.

Затем, чтобы понять, как работают более продвинутые архитектуры, такие как LSTM и GRU, можно представить их как улучшенные версии RNN с более сложными механизмами обновления скрытого состояния, которые позволяют им эффективнее учитывать долгосрочные зависимости в дан-

ных.

Для реализации рекуррентной нейронной сети (RNN) в коде на Python с использованием библиотеки глубокого обучения TensorFlow, можно следовать следующему шаблону. В данном примере будет использован простой пример классификации текста с использованием RNN:

```
```python
import tensorflow as tf
from tensorflow.keras.layers import Embedding,
SimpleRNN, Dense
from tensorflow.keras.models import Sequential
from tensorflow.keras.preprocessing.text import Tokenizer
from tensorflow.keras.preprocessing.sequence import
pad_sequences
Пример текстовых данных для обучения
texts = ["Сегодняшняя погода очень хорошая.", "Дождь
идет весь день.", "Ветер сильный, но солнце светит."]
labels = [1, 0, 1] # 1 – положительное, 0 – отрицательное
Создание токенизатора и преобразование текста в по-
следовательности чисел
tokenizer = Tokenizer()
tokenizer.fit_on_texts(texts)
sequences = tokenizer.texts_to_sequences(texts)
Паддинг последовательностей для обеспечения одина-
ковой длины
max_sequence_length = max([len(seq) for seq in sequences])
```

```
sequences = pad_sequences(sequences,
maxlen=max_sequence_length)
Создание модели RNN
model = Sequential()
model.add(Embedding(input_dim=len(tokenizer.word_index)
+ 1, output_dim=64, input_length=max_sequence_length))
model.add(SimpleRNN(32))
model.add(Dense(1, activation='sigmoid')) # Бинарная клас-
сификация
Компиляция модели
model.compile(optimizer='adam',
loss='binary_crossentropy', metrics=['accuracy'])
Обучение модели
model.fit(sequences, labels, epochs=10, batch_size=1)
Пример тестовых данных для предсказания
test_texts = ["Завтра будет солнечно.", "Дождь мне не нра-
вится."]
test_sequences = tokenizer.texts_to_sequences(test_texts)
test_sequences = pad_sequences(test_sequences,
maxlen=max_sequence_length)
Предсказание классов
predictions = model.predict(test_sequences)
for i, text in enumerate(test_texts):
sentiment = "положительное" if predictions[i] > 0.5 else "от-
рицательное"
print(f"Текст: {text}, Прогноз тональности: {sentiment}")
```

Этот код демонстрирует базовую реализацию RNN для задачи анализа тональности текста. Важно отметить, что в реальных приложениях могут использоваться более сложные архитектуры и данные.

## **2. Обратные связи (Feedback Loops):**

Обратные связи (Feedback Loops) представляют собой ключевой механизм в рекуррентных нейронных сетях (RNN) и других последовательных моделях машинного обучения. Эти обратные связи обеспечивают возможность информации циркулировать между различными моментами времени в последовательности данных, позволяя предыдущим шагам влиять на текущие вычисления. Давайте более подробно разберемся, как это работает:

### **1. Последовательные данные:**

Обратные связи особенно полезны при работе с последовательными данными, такими как тексты, временные ряды или аудиосигналы, где значения зависят от предыдущих значений.

### **2. Скрытое состояние:**

Основной механизм обратной связи в RNN заключается в использовании скрытого состояния (Hidden State). На каждом временном шаге RNN обновляет свое скрытое состояние с учетом текущего входа и предыдущего состояния.

### **3. Информация о контексте:**

Скрытое состояние сохраняет информацию о предыду-

щих элементах последовательности. Это позволяет модели учитывать контекст и зависимости между данными в разных частях последовательности.

#### 4. Пример работы:

Давайте представим следующую последовательность слов: "Я ел бутерброд. Затем я выпил чашку кофе." В контексте обратных связей, RNN начнет с анализа слова "Я", и его скрытое состояние будет содержать информацию о нем. Когда сеть перейдет к слову "ел", скрытое состояние будет учитывать и слово "Я", и слово "ел". Затем, когда сеть дойдет до "бутерброд", скрытое состояние будет содержать информацию о всех трех предыдущих словах. Это позволяет модели понимать, что "ел" – это глагол, относящийся к действию, начатому в предыдущем предложении.

#### 5. Затухание и взрыв градиентов:

Важно отметить, что обратные связи также могут быть источником проблем, таких как затухание и взрыв градиентов. Если градиенты становятся слишком большими (взрыв градиентов) или слишком маленькими (затухание градиентов), обучение RNN может стать затруднительным. Для решения этой проблемы были разработаны модификации RNN, такие как LSTM и GRU, которые эффективнее управляют обратными связями и градиентами.

Обратные связи и скрытое состояние позволяют RNN учитывать контекст и зависимости в последовательных данных, что делает их мощными инструментами в обработке

текста, аудио и других последовательных данных.

Для наглядности работы обратных связей (Feedback Loops) в рекуррентных нейронных сетях (RNN), давайте представим упрощенную аналогию. Допустим, у нас есть "ум" с карандашом, который пытается решить математическую задачу, но его способность решать задачи основывается на информации, которую он имеет о предыдущих задачах. Это можно представить следующим образом:

Первая задача: Ум начинает решать математическую задачу:  $2 + 2$ . Он записывает результат, равный 4, на листе бумаги.

Обратная связь: Теперь, когда ум попытается решить следующую задачу, он видит результат предыдущей задачи на своей записи. Это дает ему контекст и информацию для решения следующей задачи.

Вторая задача:  $3 + 3$ . Ум видит, что в предыдущей задаче было  $2 + 2 = 4$ . Это важная информация, которая позволяет ему сделать вывод о том, как правильно решить новую задачу. Он записывает результат 6 на бумаге.

Продолжение обратных связей: Процесс продолжается. Каждая задача дополняет записи ума, и он использует информацию из предыдущих задач для решения новых задач.

Таким образом, информация из предыдущих задач (или моментов времени) влияет на текущие вычисления и помогает уму (или нейронной сети) учитывать контекст и зависимости между задачами (или данными) в последовательно-

сти. Это аналогия к тому, как обратные связи в RNN позволяют модели учитывать контекст и зависимости в последовательных данных, обновляя скрытое состояние на каждом временном шаге.

### **3. Параметры, обучаемые сетью:**

Параметры, обучаемые сетью, играют критическую роль в работе рекуррентных нейронных сетей (RNN). Эти параметры являются настраиваемыми переменными, которые сеть использует для адаптации к конкретной задаче путем оптимизации их с использованием методов, таких как градиентный спуск. Вот подробное объяснение этого концепта:

#### **1. Параметры сети:**

– Веса (Weights): Веса связей между нейронами внутри RNN. Эти веса определяют, как информация передается от одного нейрона к другому и как она обновляется на каждом временном шаге.

– Смещения (Biases): Смещения добавляются к взвешенной сумме входов, перед применением активационной функции, и могут управлять смещением активации нейронов.

2. Инициализация параметров: Параметры RNN обычно инициализируются случайными значениями перед началом обучения. Эти начальные значения могут быть заданы случайным образом или с использованием различных методов инициализации весов.

3. Обучение сети: Во время обучения RNN параметры модели настраиваются для минимизации функции потерь (loss

function) на тренировочных данных. Это происходит с использованием методов оптимизации, таких как градиентный спуск (gradient descent).

4. Градиентный спуск – это оптимизационный метод, который используется для обновления параметров сети на каждом этапе обучения. Он вычисляет градиент (производные) функции потерь по параметрам сети и обновляет параметры в направлении, которое минимизирует функцию потерь.

5. Итерации обучения: Обучение RNN происходит итеративно на множестве тренировочных данных. На каждой итерации параметры обновляются таким образом, чтобы уменьшить ошибку модели на тренировочных данных.

6. Результат обучения: После завершения обучения параметры RNN настроены таким образом, чтобы модель могла делать предсказания на новых данных, которые она ранее не видела.

7. Тонкая настройка: Важно отметить, что оптимизация параметров RNN – это искусство, и существует много методов для тонкой настройки параметров и параметров оптимизации, чтобы достичь лучшей производительности на конкретной задаче.

Параметры, обучаемые сетью, позволяют RNN адаптироваться к различным задачам и данным, делая их мощным инструментом для разнообразных задач, связанных с последовательными данными, включая обработку текста, анализ временных рядов и многое другое.

Давайте рассмотрим пример использования обучаемых параметров в нейронной сети на языке Python с использованием библиотеки TensorFlow. В этом примере мы создадим простую RNN для задачи прогнозирования временных рядов.

```
```python
import numpy as np
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import SimpleRNN, Dense
# Генерируем пример временного ряда
np.random.seed(0)
n_steps = 100
time = np.linspace(0, 10, n_steps)
series = 0.1 * time + np.sin(time)
# Подготавливаем данные для обучения RNN
n_steps = 30 # количество временных шагов в одной последовательности
n_samples = len(series) - n_steps
X = [series[i:i+n_steps] for i in range(n_samples)]
y = series[n_steps:]
X = np.array(X).reshape(-1, n_steps, 1)
y = np.array(y)
# Создаем модель RNN
model = Sequential()
model.add(SimpleRNN(10, activation="relu",
```

```
input_shape=[n_steps, 1]))
    model.add(Dense(1))
    # Компилируем модель
    model.compile(optimizer="adam", loss="mse")
    # Обучаем модель
    model.fit(X, y, epochs=10)
    # Делаем прогноз на будущее
    future_steps = 10
    future_x = X[-1, :, :]
    future_predictions = []
    for _ in range(future_steps):
        future_pred = model.predict(future_x.reshape(1, n_steps, 1))
        future_predictions.append(future_pred[0, 0])
        future_x = np.roll(future_x, shift=-1)
        future_x[-1] = future_pred[0, 0]
    # Выводим результаты
    import matplotlib.pyplot as plt
    plt.plot(np.arange(n_steps), X[-1, :, 0], label="Исходные
данные")
    plt.plot(np.arange(n_steps, n_steps+future_steps),
future_predictions, label="Прогноз")
    plt.xlabel("Временной шаг")
    plt.ylabel("Значение")
    plt.legend()
    plt.show()
```

значение

1.0

1.5



В этом примере:

- Мы создаем простую RNN с одним слоем, который прогнозирует следующее значение временного ряда на основе предыдущих значений.

- Обучаем модель с использованием оптимизатора "adam" и функции потерь "mse" (Mean Squared Error).

- Затем делаем прогнозы на несколько временных шагов вперед, обновляя входные данные с учетом предсказанных значений.

На результате кода, который вы предоставили, мы видим следующее:

1. Исходные данные (синяя линия): Это начальная часть временного ряда, который был сгенерирован. В данном случае, это линейная функция ($0.1 * \text{time}$) с добавленными синусоидальными колебаниями ($\text{np.sin}(\text{time})$).

2. Прогноз (оранжевая линия): Это результаты прогноза, сделанные моделью RNN на будущее. Модель обучается на исходных данных и затем пытается предсказать значения временного ряда на заданное количество временных шагов вперед (`future_steps`).

Из этой визуализации видно, как модель RNN пытается аппроксимировать исходный временной ряд и делает прогнозы на основе предыдущих значений. Оранжевая линия отображает прогнозируемую часть временного ряда на будущее.

Завершив обучение и сделав прогнозы, вы можете визу-

ально оценить, насколько хорошо модель справилась с задачей прогнозирования временного ряда.

В этом примере обучаемые параметры модели – это веса и смещения в слое RNN и в слое Dense. Модель настраивает эти параметры в процессе обучения, чтобы минимизировать ошибку прогноза временного ряда.

Обучаемые параметры позволяют модели адаптироваться к данным и находить закономерности, что делает их мощным инструментом для разнообразных задач машинного обучения.

Однако RNN имеют несколько ограничений, из которых наиболее значимой является проблема **затухания градиентов** (vanishing gradients). Эта проблема заключается в том, что при обучении RNN градиенты (производные функции потерь по параметрам сети) могут становиться очень маленькими, особенно на длинных последовательностях. Это затрудняет обучение, поскольку сеть может "забывать" информацию о давно прошедших событиях в последовательности.

Для решения проблемы затухания градиентов были разработаны более продвинутые архитектуры RNN:

Long Short-Term Memory (LSTM):

Long Short-Term Memory (LSTM) – это одна из наиболее популярных архитектур в области рекуррентных нейронных сетей (RNN). Она разработана для работы с последовательными данными и способна эффективно учитывать долгосрочные зависимости в данных. Давайте подробнее разбе-

рем, как работает LSTM:

Специальные ячейки LSTM: Основная особенность LSTM заключается в использовании специальных ячеек памяти, которые позволяют сохранять и извлекать информацию из прошлых состояний. Эти ячейки состоят из нескольких внутренних гейтов (гейт – это устройство, которое решает, какая информация должна быть сохранена и какая должна быть проигнорирована).

Забывающий гейт (Forget Gate): Этот гейт определяет, какая информация из прошлых состояний следует забыть или удалить из памяти ячейки. Он работает с текущим входом и предыдущим состоянием и выдает значение от 0 до 1 для каждой информации, которая указывает, следует ли ее забыть или сохранить.

Входной гейт (Input Gate): Этот гейт определяет, какая информация из текущего входа должна быть добавлена в память ячейки. Он также работает с текущим входом и предыдущим состоянием, и вычисляет, какие значения следует обновить.

Обновление памяти (Cell State Update): На этом этапе обновляется состояние памяти ячейки на основе результатов забывающего гейта и входного гейта. Это новое состояние памяти будет использоваться на следующем временном шаге.

Выходной гейт (Output Gate): Этот гейт определяет, какую информацию из текущего состояния памяти следует исполь-

зовать на выходе. Он учитывает текущий вход и предыдущее состояние, чтобы определить, какую информацию передать на выход.

Долгосрочные зависимости: Благодаря специальным ячейкам и гейтам, LSTM способна учитывать долгосрочные зависимости в данных. Она может эффективно хранить информацию на протяжении многих временных шагов и извлекать ее, когда это необходимо.

Применение LSTM: LSTM широко используется в задачах, связанных с последовательными данными, таких как обработка текста, анализ временных рядов, машинный перевод, генерация текста и многие другие. Ее способность учитывать долгосрочные зависимости делает ее мощным инструментом для анализа и моделирования последовательных данных.

Лучший способ понять, как работает Long Short-Term Memory (LSTM), – это применить его на практике в рамках конкретной задачи. Давайте рассмотрим пример применения LSTM для анализа временных рядов в Python с использованием библиотеки TensorFlow и библиотеки pandas:

```
```python
import numpy as np
import tensorflow as tf
import pandas as pd
import matplotlib.pyplot as plt
from tensorflow.keras.models import Sequential
```

```
from tensorflow.keras.layers import LSTM, Dense
Генерируем пример временного ряда (синусоида)
timesteps = np.linspace(0, 100, 400)
series = np.sin(timesteps)
Создаем датасет для обучения сети
df = pd.DataFrame({'timesteps': timesteps, 'series': series})
window_size = 10 # Размер окна для создания последовательных образцов
batch_size = 32 # Размер пакета
Функция для создания последовательных образцов из временного ряда
def create_sequences(series, window_size, batch_size):
 dataset = tf.data.Dataset.from_tensor_slices(series)
 dataset = dataset.window(window_size + 1, shift=1, drop_remainder=True)
 dataset = dataset.flat_map(lambda window: window.batch(window_size + 1))
 dataset = dataset.shuffle(1000).map(lambda window: (window[:-1], window[-1]))
 dataset = dataset.batch(batch_size).prefetch(1)
 return dataset
train_dataset = create_sequences(series, window_size, batch_size)
Создаем модель LSTM
model = Sequential([
 LSTM(50, return_sequences=True, input_shape=[None, 1]),
```

```

LSTM(50),
Dense(1)
])
Компилируем модель
model.compile(loss='mse', optimizer='adam')
Обучаем модель
model.fit(train_dataset, epochs=10)
Делаем прогноз на будущее
future_timesteps = np.arange(100, 140, 1)
future_series = []
for i in range(len(future_timesteps) - window_size):
 window = series[i:i + window_size]
 prediction = model.predict(window[np.newaxis])
 future_series.append(prediction[0, 0])
Визуализируем результаты
plt.figure(figsize=(10, 6))
plt.plot(timesteps, series, label="Исходный ряд",
linewidth=2)
plt.plot(future_timesteps[:-window_size], future_series,
label="Прогноз", linewidth=2)
plt.xlabel("Время")
plt.ylabel("Значение")
plt.legend()
plt.show()
'''

```

Этот пример демонстрирует, как можно использовать

LSTM для прогнозирования временных рядов. Мы создаем модель LSTM, обучаем ее на исходном временном ряде и делаем прогнозы на будущее. Визуализация показывает, как модель способна улавливать долгосрочные зависимости в данных и строить прогно-

чение

0.0

0.5

1.0



На результате данного примера мы видим следующее:

1. Исходный временной ряд (синяя линия): Это синусоидальная волна, которая была сгенерирована как пример временного ряда.

2. Прогноз модели (оранжевая линия): Это результаты прогноза, сделанные моделью LSTM на будущее. Модель пытается предсказать значения временного ряда на основе предыдущих значений. Оранжевая линия отображает прогнозируемую часть временного ряда.

Из этой визуализации видно, что модель LSTM смогла захватить основные характеристики синусоидального временного ряда и предсказать его продолжение на будущее. Этот пример демонстрирует, как LSTM может использоваться для анализа и прогнозирования временных рядов, а также как она учитывает долгосрочные зависимости в данных.

## **2. Gated Recurrent Unit (GRU):**

GRU (Gated Recurrent Unit) – это архитектура рекуррентных нейронных сетей (RNN), которая, как вы сказали, является более легкой и вычислительно эффективной по сравнению с LSTM (Long Short-Term Memory). GRU была разработана для решения проблемы затухания градиентов, которая является одной из основных проблем при обучении RNN.

Вот основные характеристики GRU:

1. Воротные механизмы (Gating Mechanisms): GRU также использует воротные механизмы, как LSTM, но в упрощенной форме. У нее есть два ворота – ворот восстановления

(Reset Gate) и ворот обновления (Update Gate).

2. Ворота восстановления (Reset Gate): Этот вент решлет, какую информацию из предыдущего состояния следует забыть. Если сброс (reset) равен 1, то модель забывает всю информацию. Если сброс равен 0, то вся информация сохраняется.

3. Ворота обновления (Update Gate): Этот вент определяет, какая информация из нового входа следует использовать. Если значение вента обновления близко к 1, то новая информация будет использоваться практически полностью. Если близко к 0, то новая информация будет игнорироваться.

4. Скрытое состояние (Hidden State): GRU также имеет скрытое состояние, которое передается от одного временно-го шага к другому. Однако, в отличие от LSTM, GRU не имеет ячейки памяти, что делает ее более легкой.

5. Затухание градиентов: GRU спроектирована так, чтобы бороться с проблемой затухания градиентов, которая может возникнуть при обучении глубоких RNN. Благодаря вентным механизмам, GRU может регулировать поток информации и избегать слишком быстрого затухания или взрывного увеличения градиентов.

6. Применение: GRU часто применяется в задачах анализа текста, временных рядов и других последовательных данных. Она обеспечивает хорошее соотношение между производительностью и сложностью модели, что делает ее популярным выбором во многих приложениях.

Главное преимущество GRU перед LSTM заключается в более низкой сложности и меньшем количестве параметров, что может быть важно при работе с ограниченными вычислительными ресурсами. Однако, стоит отметить, что LSTM всё равно остается более мощным в решении некоторых сложных задач, требующих учета долгосрочных зависимостей.

Давайте рассмотрим пример кода, в котором используется GRU для анализа временного ряда. В этом примере мы будем использовать библиотеку TensorFlow:

```
```python
import numpy as np
import tensorflow as tf
import matplotlib.pyplot as plt
# Генерируем пример временного ряда (синусоида с шумом)
np.random.seed(0)
n_steps = 100
time = np.linspace(0, 10, n_steps)
series = 0.1 * time + np.sin(time) +
np.random.randn(n_steps) * 0.1
# Подготавливаем данные для обучения GRU
n_steps = 30 # количество временных шагов в одной последовательности
n_samples = len(series) - n_steps
X = [series[i:i+n_steps] for i in range(n_samples)]
```

```
y = series[n_steps:]
X = np.array(X).reshape(-1, n_steps, 1)
y = np.array(y)
# Создаем модель GRU
model = tf.keras.Sequential([
    tf.keras.layers.GRU(10,                                activation="relu",
input_shape=[n_steps, 1]),
    tf.keras.layers.Dense(1)
])
# Компилируем модель
model.compile(optimizer="adam", loss="mse")
# Обучаем модель
model.fit(X, y, epochs=10)
# Делаем прогноз на будущее
future_steps = 10
future_x = X[-1, :, :]
future_predictions = []
for _ in range(future_steps):
    future_pred = model.predict(future_x.reshape(1, n_steps, 1))
    future_predictions.append(future_pred[0, 0])
    future_x = np.roll(future_x, shift=-1)
    future_x[-1] = future_pred[0, 0]
# Выводим результаты
plt.plot(np.arange(n_steps), X[-1, :, 0], label="Исходные
данные")
plt.plot(np.arange(n_steps,                                n_steps+future_steps),
```

```
future_predictions, label="Прогноз")
plt.xlabel("Временной шаг")
plt.ylabel("Значение")
plt.legend()
plt.show()
```

значение

1.2

1.4

1.6

1.8



В этом коде мы создаем и обучаем модель GRU для анализа временного ряда, а затем делаем прогнозы на будущее. Результаты прогнозирования отображаются на графике вместе с исходными данными.

На результате кода вы увидите график, который содержит две линии:

1. Исходные данные (синяя линия): Это начальная часть временного ряда, который был сгенерирован. В данном случае, это синусоидальная волна с добавленным случайным шумом.

2. Прогноз (оранжевая линия): Это результаты прогноза, сделанные моделью GRU на будущее. Модель обучается на исходных данных и затем пытается предсказать значения временного ряда на заданное количество временных шагов вперед (`future_steps`).

Из этой визуализации можно оценить, насколько хорошо модель справилась с задачей прогнозирования временного ряда. Оранжевая линия отображает прогнозируемую часть временного ряда на будущее. В зависимости от точности модели и сложности данных, результаты могут быть близкими к исходным данным или иметь некоторую степень погрешности.

GRU может использоваться для анализа и прогнозирования временных рядов, учитывая долгосрочные зависимости в данных.

3. Bidirectional RNN (BiRNN):

Bidirectional RNN (BiRNN) – это архитектура рекуррентных нейронных сетей (RNN), которая позволяет модели использовать информацию из прошлых и будущих состояний в последовательности данных. Это значительно улучшает способность модели к пониманию контекста и делает ее более мощной в анализе последовательных данных.

Вот ключевые особенности и принцип работы Bidirectional RNN:

1. **Двунаправленность (Bidirectionality)**: Основная идея заключается в том, чтобы иметь два набора рекуррентных слоев – один, который проходит последовательность слева направо (forward), и другой, который проходит последовательность справа налево (backward). Это позволяет модели анализировать информацию как в прошлом, так и в будущем относительно текущего временного шага.

2. **Объединение информации**: После прохождения последовательности в обоих направлениях, информация из обоих наборов рекуррентных слоев объединяется. Обычно это делается путем конкатенации или другой операции объединения. Это создает более богатое представление данных, которое учитывает как контекст слева, так и контекст справа от текущего временного шага.

3. **Улучшенное понимание контекста**: Благодаря двунаправленному подходу, модель становится более способной понимать широкий контекст данных. Это особенно полезно в задачах, где важны как предыдущие, так и последующие

элементы в последовательности, например, в обработке естественного языка (NLP), распознавании речи и анализе временных рядов.

4. Применение: BiRNN может быть успешно применена во многих задачах, включая именованное сущности извлечение в тексте, машинный перевод, анализ эмоций в тексте, распознавание речи и другие. Всюду где важен контекст, BiRNN может улучшить производительность модели.

Давайте рассмотрим пример задачи, в которой Bidirectional RNN (BiRNN) может быть полезной, а затем проведем подробный разбор.

Задача: Сентимент-анализ текста

Цель задачи: Определить эмоциональную окраску (позитивную, негативную или нейтральную) текстового отзыва о продукте, услуге или событии.

Пример задачи: Допустим, у вас есть набор отзывов о фильмах, и вы хотите определить, какие из них положительные, а какие – отрицательные.

Решение с использованием BiRNN:

1. Подготовка данных: Начнем с подготовки данных. Ваши текстовые отзывы будут представлены в виде последовательности слов. Каждое слово можно представить в виде вектора, например, с использованием метода Word2Vec или других эмбеддингов. Затем тексты будут преобразованы в последовательности векторов слов.

2. Архитектура BiRNN: Затем мы создадим BiRNN для анализа текстовых отзывов. BiRNN состоит из двух частей: RNN, который анализирует текст слева направо (forward), и RNN, который анализирует текст справа налево (backward). Оба RNN объединяют свои выводы.

3. Обучение модели: На этом этапе мы разделим данные на обучающий, валидационный и тестовый наборы. Затем мы обучим BiRNN на обучающем наборе, используя метки сентимента (позитивный, негативный, нейтральный) как целевую переменную. Модель будет обучаться на обучающих данных с целью научиться выявлять эмоциональную окраску текстов.

4. Оценка модели: После обучения мы оценим производительность модели на валидационном наборе данных, используя метрики, такие как точность, полнота, F1-мера и др. Это позволит нам оптимизировать гиперпараметры модели и выбрать лучшую модель.

5. Прогнозирование: После выбора лучшей модели мы можем использовать ее для анализа новых отзывов и определения их сентимента.

Почему BiRNN полезна в этой задаче:

– BiRNN может анализировать контекст текста с обеих сторон, что позволяет модели учесть как контекст в начале текста, так и контекст в его конце. Это особенно полезно при анализе длинных текстов, где важна общая смысловая зависимость.

– Она позволяет учесть последовательность слов в тексте, что важно для анализа текстовых данных.

– BiRNN способна обнаруживать сложные зависимости и взаимодействия между словами в тексте, что делает ее мощным инструментом для задачи сентимент-анализа.

В итоге, использование BiRNN в задаче сентимент-анализа текста позволяет модели более глубоко понимать эмоциональную окраску текстов и делать более точные прогнозы.

Давайте представим пример кода для задачи сентимент-анализа текста с использованием Bidirectional RNN (BiRNN) и библиотеки TensorFlow. Этот код будет простым примером и не будет включать в себя полный процесс обработки данных, но он поможет вам понять, как создать модель и провести обучение. Обратите внимание, что в реальном проекте вам потребуется более тщательно обработать данные и выполнить настройку модели.

```
``python
import numpy as np
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Embedding,
Bidirectional, LSTM, Dense
from tensorflow.keras.preprocessing.text import Tokenizer
from tensorflow.keras.preprocessing.sequence import
pad_sequences
# Подготовка данных (пример)
```

```
texts = ["Этот фильм был ужасным.", "Я очень доволен  
этим продуктом.", "Сюжет был интересным."]  
labels = [0, 1, 1] # 0 – негативный sentiment, 1 – позитив-  
ный sentiment  
# Tokenization of texts and transformation into numerical se-  
quences  
tokenizer = Tokenizer()  
tokenizer.fit_on_texts(texts)  
sequences = tokenizer.texts_to_sequences(texts)  
word_index = tokenizer.word_index  
# Preparation of sequences for training  
max_sequence_length = max([len(seq) for seq in sequences])  
sequences = pad_sequences(sequences,  
maxlen=max_sequence_length)  
# Creation of BiRNN model  
model = Sequential()  
model.add(Embedding(len(word_index) + 1, 128,  
input_length=max_sequence_length))  
model.add(Bidirectional(LSTM(64)))  
model.add(Dense(1, activation='sigmoid'))  
# Compilation of model  
model.compile(loss='binary_crossentropy',  
optimizer='adam', metrics=['accuracy'])  
# Training of model  
X = np.array(sequences)  
y = np.array(labels)
```

```
model.fit(X, y, epochs=5)
# Прогнозирование
new_texts = ["Это лучший фильм, который я видел!", "Не
стоит тратить время на это.", "Продукт среднего качества."]
new_sequences = tokenizer.texts_to_sequences(new_texts)
new_sequences = pad_sequences(new_sequences,
maxlen=max_sequence_length)
predictions = model.predict(new_sequences)
for i, text in enumerate(new_texts):
    sentiment = "позитивный" if predictions[i] > 0.5 else "нега-
тивный"
    print(f"Текст: '{text}' – Сентимент: {sentiment}")
```

Epoch 1/5

1/1 [=====]

Epoch 2/5

1/1 [=====]

Epoch 3/5

1/1 [=====]

Epoch 4/5

1/1 [=====]

Epoch 5/5

1/1 [=====]

1/1 [=====]

Текст: 'Это лучши

Результат выполнения кода, представленного выше, будет включать в себя обучение модели на небольшом наборе данных (трех текстах) и прогнозирование сентимента для трех новых текстов. Каждый из новых текстов будет ассоциирован с позитивным или негативным сентиментом на основе предсказаний модели. Результаты будут выводиться на экран.

Этот вывод показывает результаты обучения модели (значения потерь и точности на каждой эпохе обучения) и, затем, результаты прогнозирования сентимента для новых текстов. Модель выдает "позитивный" или "негативный" сентимент на основе порогового значения (обычно 0.5) для выхода сигмоидальной активации.

Этот код демонстрирует основные шаги, необходимые для создания BiRNN модели для задачи сентимент-анализа текста. Ключевые моменты включают в себя токенизацию текстов, преобразование их в числовые последовательности, создание BiRNN модели, обучение на обучающих данных и прогнозирование на новых текстах.

Обратите внимание, что этот код предоставляет базовый каркас, и в реальных проектах вам потребуется более тщательная обработка данных, настройка гиперпараметров модели и оценка производительности.

Однако, стоит отметить, что BiRNN более сложная архитектура с большим числом параметров, чем обычные однонаправленные RNN, и поэтому требует больше вычислительных ресурсов для обучения и выполнения.

RNN, LSTM и GRU широко применяются в NLP для решения задач, таких как машинный перевод, анализ тональности текста, генерация текста и другие, где важен контекст и последовательность данных. Они позволяют моделям учитывать зависимости между словами и долгосрочные взаимосвязи в тексте, что делает их мощными инструментами для обработки текстовых данных.

Рассмотрим еще одну задачу, в которой можно использовать Bidirectional RNN (BiRNN). В этом примере мы будем решать задачу определения языка текста .

Пример задачи: Определение языка текста

Цель задачи: Определить, на каком языке написан данный текст.

Пример задачи: У вас есть набор текстов, и вам нужно автоматически определить, на каком языке каждый из них написан (например, английский, испанский, французский и т. д.).

Решение с использованием BiRNN:

1. Подготовка данных: Вам нужно иметь набор данных с текстами, для которых известен язык. Эти тексты должны быть предварительно обработаны и токенизированы.

2. Архитектура BiRNN: Создаем модель BiRNN для анализа текста. BiRNN будет принимать последовательности слов (токенов) из текстов и строить контекст как слева, так и справа от текущего слова. В конце модели добавляем слой

с количеством классов, равным числу языков.

3. Обучение модели: Используйте размеченные данные для обучения модели. Модель должна учиться выделять признаки из текста, которые характеризуют язык.

4. Оценка модели: Оцените производительность модели на отложенных данных с помощью метрик, таких как точность, полнота и F1-мера, чтобы измерить ее способность определения языка текста.

5. Применение модели: После успешного обучения модель можно использовать для определения языка новых текстов.

Пример кода на Python с использованием TensorFlow и Keras для решения задачи определения языка текста с помощью BiRNN:

```
import numpy as np
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Bidirectional, LSTM,
Embedding, Dense
from tensorflow.keras.preprocessing.text import Tokenizer
from tensorflow.keras.preprocessing.sequence import
pad_sequences
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import LabelEncoder
from sklearn.metrics import accuracy_score
# Подготовка размеченных данных (в этом примере, дан-
```

ные просто для иллюстрации)

```
texts = ["Bonjour, comment ça va?", "Hello, how are you?",
";Hola, cómo estás?"]
labels = ["French", "English", "Spanish"]
# Преобразуем метки в числа
label_encoder = LabelEncoder()
y = label_encoder.fit_transform(labels)
# Создаем токенизатор и преобразуем тексты в последо-
вательности чисел
tokenizer = Tokenizer()
tokenizer.fit_on_texts(texts)
word_index = tokenizer.word_index
sequences = tokenizer.texts_to_sequences(texts)
# Подготавливаем данные для модели, включая паддинг
max_sequence_length = max([len(seq) for seq in sequences])
padded_sequences = pad_sequences(sequences,
maxlen=max_sequence_length)
# Разделяем данные на обучающий и тестовый наборы
x_train, x_test, y_train, y_test =
train_test_split(padded_sequences, y, test_size=0.2,
random_state=42)
# Создаем модель BiRNN
model = Sequential()
model.add(Embedding(input_dim=len(word_index) + 1,
output_dim=100, input_length=max_sequence_length))
model.add(Bidirectional(LSTM(50)))
```

```
model.add(Dense(len(set(y)), activation="softmax")) # Ко-
личество классов равно количеству языков
# Компилируем модель
model.compile(loss="sparse_categorical_crossentropy",
optimizer="adam", metrics=["accuracy"])
# Обучаем модель
model.fit(x_train, y_train, epochs=10, validation_split=0.2)
# Оцениваем модель на тестовых данных
y_pred = model.predict(x_test)
y_pred = np.argmax(y_pred, axis=1)
accuracy = accuracy_score(y_test, y_pred)
print(f"Точность: {accuracy:.4f}")
```

```
Epoch 1/10
1/1 [=====] - 6s 6s/step - loss: 1.1120 - accuracy: 0.0000e+0
Epoch 2/10
1/1 [=====] - 0s 64ms/step - loss: 1.0902 - accuracy: 1.0000
Epoch 3/10
1/1 [=====] - 0s 43ms/step - loss: 1.0684 - accuracy: 1.0000
Epoch 4/10
1/1 [=====] - 0s 59ms/step - loss: 1.0464 - accuracy: 1.0000
Epoch 5/10
1/1 [=====] - 0s 44ms/step - loss: 1.0239 - accuracy: 1.0000
Epoch 6/10
1/1 [=====] - 0s 66ms/step - loss: 1.0007 - accuracy: 1.0000
Epoch 7/10
1/1 [=====] - 0s 62ms/step - loss: 0.9766 - accuracy: 1.0000
Epoch 8/10
1/1 [=====] - 0s 60ms/step - loss: 0.9514 - accuracy: 1.0000
Epoch 9/10
1/1 [=====] - 0s 60ms/step - loss: 0.9248 - accuracy: 1.0000
Epoch 10/10
1/1 [=====] - 0s 44ms/step - loss: 0.8967 - accuracy: 1.0000
WARNING:tensorflow:6 out of the last 15 calls to <function Model.make_predict_function
1/1 [=====] - 1s 1s/step
Точность: 0.0000
```

В результате выполнения данного кода будет видно следу-

ющее:

1. Модель BiRNN будет обучаться на предоставленных текстах для классификации на языки.

2. В конце каждой эпохи обучения будет выводиться информация о значении функции потерь (loss) и метрике точности (accuracy) на обучающем и валидационном наборах данных. Эти значения позволяют оценить процесс обучения модели.

3. После завершения обучения модели будет выведена метрика точности (accuracy) на тестовом наборе данных, которая покажет, насколько хорошо модель классифицирует языки текстов.

4. Обратите внимание на строки, где используется `print(f"Точность: {accuracy:.4f}")`. Здесь вы увидите точность классификации, округленную до четырех знаков после запятой, что делает результаты более наглядными.

5. В данном коде используется модель BiRNN для классификации текстов на три языка: французский, английский и испанский. Тексты в переменной `texts` представляют собой примеры текстов на этих языках.

Обратите внимание, что в данном коде используются данные, предоставленные для иллюстрации, и они могут быть недостаточными для реальной задачи. Для более точных результатов требуется больший объем данных и более разнообразные тексты на разных языках.

Далее, вы можете создать модель BiRNN и обучить ее на

этом обучающем наборе данных, а также протестировать ее на новых текстах для распознавания именованных сущностей.

Сверточные нейронные сети (CNN):

CNN, которые изначально разрабатывались для обработки изображений, также нашли применение в NLP. Сверточные слои в CNN могут применяться к тексту так же, как они применяются к изображениям, с учетом локальных контекстов. Это дало начало таким архитектурам, как Convolutional Neural Network for Text (CNN-text), и позволило обрабатывать тексты в NLP:

– Классификация текста:

Классификация текста с использованием сверточных нейронных сетей (CNN) – это мощный метод, который позволяет определять, к какой категории или метке относится текстовый документ. В данном разделе мы рассмотрим этот процесс подробнее на примере. Предположим, у нас есть набор новостных статей, и наша задача – классифицировать их на несколько категорий, такие как "Политика", "Спорт", "Экономика" и "Наука".

Шаги классификации текста с использованием CNN:

Подготовка данных:

– Сначала необходимо собрать и подготовить набор данных для обучения и тестирования. Этот набор данных должен включать в себя тексты статей и соответствующие метки

(категории).

Токенизация и векторизация:

– Тексты статей нужно токенизировать, разбив их на слова или подслова (токены). Затем каждый токен представляется вектором, например, с использованием методов word embedding, таких как Word2Vec или GloVe. Это позволяет нейросети работать с числовыми данными вместо текста.

Подготовка последовательностей:

– Токенизированные тексты преобразуются в последовательности фиксированной длины. Это важно для того, чтобы иметь одинаковую длину входных данных для обучения модели.

Создание CNN модели:

– Далее создается модель сверточной нейронной сети (CNN). Модель состоит из нескольких слоев, включая сверточные слои и пулинг слои. Сверточные слои используются для извлечения признаков из текста, а пулинг слои уменьшают размерность данных.

– После сверточных слоев добавляются полносвязные слои для классификации текста по категориям.

Компиляция модели:

– Модель компилируется с оптимизатором, функцией потерь и метриками. Функция потерь обычно является категориальной кросс-энтропией для многоклассовой классификации, а метрикой может быть точность (ассигасу).

Обучение модели:

– Модель обучается на обучающем наборе данных в течение нескольких эпох. В процессе обучения модель корректирует свои веса и настраивается для лучшей классификации текста.

Оценка и тестирование:

– После обучения модель оценивается на тестовом наборе данных для оценки ее производительности. Метрики, такие как точность, полнота и F1-мера, могут использоваться для измерения качества классификации.

Применение модели:

– После успешного обучения модель можно использовать для классификации новых текстовых документов на категории.

Пример кода на Python с использованием библиотек TensorFlow и Keras для классификации текста с использованием CNN:

```
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Embedding, Conv1D,
GlobalMaxPooling1D, Dense
from tensorflow.keras.preprocessing.text import Tokenizer
from tensorflow.keras.preprocessing.sequence import
pad_sequences
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import LabelEncoder
from sklearn.metrics import accuracy_score
```

```
# Подготовка размеченных данных (пример данных)
texts = ["Политика: новости о выборах", "Спорт: результа-
ты чемпионата", "Экономика: рост ВВП", "Наука: новое ис-
следование"]

labels = ["Политика", "Спорт", "Экономика", "Наука"]
# Преобразование меток в числа
label_encoder = LabelEncoder()
y = label_encoder.fit_transform(labels)
# Токенизация и векторизация текстов
tokenizer = Tokenizer()
tokenizer.fit_on_texts(texts)
word_index = tokenizer.word_index
sequences = tokenizer.texts_to_sequences(texts)
# Подготовка последовательностей и паддинг
max_sequence_length = max([len(seq) for seq in sequences])
padded_sequences = pad_sequences(sequences,
maxlen=max_sequence_length)
# Разделение на обучающий и тестовый наборы
x_train, x_test, y_train, y_test =
train_test_split(padded_sequences, y, test_size=0.2,
random_state=42)
# Создание CNN модели
model = Sequential()
model.add(Embedding(input_dim=len(word_index) + 1,
output_dim=100, input_length=max_sequence_length))
model.add(Conv1D(128, 3, activation="relu")) # Изменено
```

```
количество фильтров и размер свертки
model.add(GlobalMaxPooling1D())
model.add(Dense(len(set(y)), activation="softmax"))
# Компиляция модели
model.compile(loss="sparse_categorical_crossentropy",
optimizer="adam", metrics=["accuracy"])
# Обучение модели
model.fit(x_train, y_train, epochs=10, validation_split=0.2)
# Оценка модели
y_pred = model.predict(x_test)
y_pred = tf.argmax(y_pred, axis=1).numpy()
accuracy = accuracy_score(y_test, y_pred)
print(f"Точность:
```

Epoch 1/10

1/1 [=====

Epoch 2/10

1/1 [=====

Epoch 3/10

1/1 [=====

Epoch 4/10

1/1 [=====

Epoch 5/10

1/1 [=====

Epoch 6/10

1/1 [=====

Результат выполнения кода, представленного выше, будет включать в себя точность классификации модели на тестовых данных. В коде это вычисляется с помощью следующей строки:

```
```python
accuracy = accuracy_score(y_test, y_pred)
```
```

`accuracy` – это значение точности, которое будет выведено на экран. Это число будет между 0 и 1 и показывает, какой процент текстов в тестовом наборе был правильно классифицирован моделью.

Интерпретация результата:

- Если точность равна 1.0, это означает, что модель идеально классифицировала все тексты в тестовом наборе и не допустила ни одной ошибки.
- Если точность равна 0.0, это означает, что модель не смогла правильно классифицировать ни один текст.
- Если точность находится между 0.0 и 1.0, это показывает процент правильно классифицированных текстов. Например, точность 0.8 означает, что модель правильно классифицировала 80% текстов.

Важно помнить, что точность – это только одна из метрик, которые можно использовать для оценки модели. Для полного понимания производительности модели также рекомендуется рассмотреть другие метрики, такие как точность

(precision), полнота (recall), F1-мера (F1-score) и матрица ошибок (confusion matrix), особенно если у вас есть несколько классов для классификации.

Этот код демонстрирует основные шаги для создания и обучения CNN модели для классификации текста. Результатом будет точность классификации текстов на категории.

Достичь абсолютной точности (1.0) в реальных задачах классификации текста обычно бывает сложно, так как тексты могут быть многозначными и содержать разнообразные варианты фраз. Тем не менее, можно создать пример кода, где модель будет совершенно точно классифицировать некоторые простые текстовые данные:

```
```python
import numpy as np
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Embedding, LSTM,
Dense
from sklearn.model_selection import train_test_split
Создадим синтетический датасет для иллюстрации
texts = ["Сегодня хорошая погода.", "Завтра будет солнечно.", "Лето – лучшее время года.", "Дождь идет весь день."]
labels = [1, 1, 2, 0] # 0 – дождь, 1 – солнце, 2 – лето
Токенизация и векторизация текстов (в данном случае,
просто индексирование)
tokenizer = tf.keras.layers.TextVectorization()
```

```
tokenizer.adapt(texts)
Создание модели LSTM
model = Sequential()
model.add(tokenizer)
model.add(Embedding(input_dim=len(tokenizer.get_vocabul
output_dim=16, input_length=6))
model.add(LSTM(16))
model.add(Dense(3, activation="softmax")) # Три класса:
дождь, солнце, лето
Компиляция модели
model.compile(loss="sparse_categorical_crossentropy",
optimizer="adam", metrics=["accuracy"])
Создание фиктивных данных для обучения и теста
x_train, x_test, y_train, y_test = train_test_split(texts, labels,
test_size=0.2, random_state=42)
Обучение модели
model.fit(x_train, y_train, epochs=10, verbose=0) # Модель
будет идеально подстраиваться под эти простые данные
Оценка модели
accuracy = model.evaluate(x_test, y_test)[1] # Извлекаем
точность из метрик
print(f"Точность: {accuracy:.4f}")
```

1/1 [=====]  
Точность: 1.0000

...

В данном коде мы имеем простой синтетический датасет с четырьмя текстами, каждому из которых присвоена уникальная метка. Модель LSTM будет идеально обучена для этого набора данных и даст точность 1.0. Однако в реальных задачах точность обычно ниже из-за сложности данных и пересечений между классами.

### – Извлечение признаков из текста:

Сверточные нейронные сети (Convolutional Neural Networks, CNN) изначально разрабатывались для обработки изображений, но они также могут быть эффективно применены для анализа текста. Одной из ключевых особенностей CNN является их способность автоматически извлекать значимые признаки из данных, что делает их полезными инструментами для анализа текстов.

Рассмотрим как работают сверточные слои в анализе текста:

1. Сверточные фильтры: Сверточные слои используют

фильтры (ядра), которые скользят (конволюцируются) по входным данным. В случае текста, фильтры скользят по последовательности слов (токенов). Фильтры представляют собой матрицы весов, которые определяют, какие признаки они будут извлекать. Фильтры могут быть разных размеров и выполнять разные операции.

2. Извлечение признаков: При скольжении фильтров по тексту они извлекают локальные признаки. Например, один фильтр может выделять биграммы (пары слов), а другой – триграммы (три слова подряд). Фильтры "аппроксимируют" части текста, выявляя важные структуры, такие как фразы, ключевые слова или грамматические конструкции.

3. Свертка и пулинг: После применения фильтров, результаты свертки подвергаются операции пулинга (pooling). Пулинг уменьшает размерность данных, оставляя только наиболее важные признаки. Операция Max-Pooling, например, выбирает максимальное значение из группы значений, что позволяет выделить самые значимые признаки.

4. Слои полносвязной нейронной сети: После извлечения признаков из текста через сверточные слои, результаты передаются на полносвязные слои нейронной сети. Эти слои выполняют классификацию, регрессию или другие задачи в зависимости от поставленной задачи. Для анализа текста это может быть задачей классификации текстов на категории или определения тональности.

Пример кода для анализа текста с использованием свер-

точных слоев на Python и библиотеке TensorFlow/Keras:

```
import tensorflow as tf
from tensorflow.keras.layers import Embedding, Conv1D,
GlobalMaxPooling1D, Dense
from tensorflow.keras.models import Sequential
from tensorflow.keras.preprocessing.text import Tokenizer
from tensorflow.keras.preprocessing.sequence import
pad_sequences
import numpy as np
Генерируем синтетический датасет для примера
texts = ["Этот фильм был ужасным!", "Отличный фильм,
рекомендую.", "Сюжет оставляет желать лучшего."]
Метки классов (положительный, отрицательный)
labels = [0, 1, 0]
Токенизация и векторизация текстов
tokenizer = Tokenizer(num_words=1000)
tokenizer.fit_on_texts(texts)
sequences = tokenizer.texts_to_sequences(texts)
Подготовка данных для модели
max_sequence_length = max([len(seq) for seq in sequences])
padded_sequences = pad_sequences(sequences,
maxlen=max_sequence_length)
Создание модели CNN для анализа текста
model = Sequential()
model.add(Embedding(input_dim=len(tokenizer.word_index)
+ 1, output_dim=100, input_length=max_sequence_length))
```

```
model.add(Conv1D(32, 3, activation='relu')) # Изменено ядро с 5 на 3 и количество фильтров с 128 на 32
model.add(GlobalMaxPooling1D())
model.add(Dense(1, activation='sigmoid'))
Компиляция модели
model.compile(optimizer='adam',
loss='binary_crossentropy', metrics=['accuracy'])
Обучение модели
x_train = padded_sequences
y_train = np.array(labels)
model.fit(x_train, y_train, epochs=10)
Оценка модели
test_text = ["Это лучший фильм, который я когда-либо видел!"]
test_sequence = tokenizer.texts_to_sequences(test_text)
padded_test_sequence = pad_sequences(test_sequence,
maxlen=max_sequence_length)
result = model.predict(padded_test_sequence)
print("Результат анализа текста:", result)
```

```
Epoch 1/10
1/1 [=====] - 2s 2s/step - loss: 0.6986 - accuracy: 0.3333
Epoch 2/10
1/1 [=====] - 0s 23ms/step - loss: 0.6750 - accuracy: 1.0000
Epoch 3/10
1/1 [=====] - 0s 33ms/step - loss: 0.6546 - accuracy: 1.0000
Epoch 4/10
1/1 [=====] - 0s 16ms/step - loss: 0.6361 - accuracy: 1.0000
Epoch 5/10
1/1 [=====] - 0s 24ms/step - loss: 0.6194 - accuracy: 1.0000
Epoch 6/10
1/1 [=====] - 0s 20ms/step - loss: 0.6035 - accuracy: 1.0000
Epoch 7/10
1/1 [=====] - 0s 15ms/step - loss: 0.5881 - accuracy: 1.0000
Epoch 8/10
1/1 [=====] - 0s 15ms/step - loss: 0.5732 - accuracy: 1.0000
Epoch 9/10
1/1 [=====] - 0s 14ms/step - loss: 0.5585 - accuracy: 1.0000
Epoch 10/10
1/1 [=====] - 0s 16ms/step - loss: 0.5437 - accuracy: 1.0000
1/1 [=====] - 0s 131ms/step
Результат анализа текста: [[0.54142547]]
```

В данном примере результатом будет число от 0 до 1, которое показывает вероятность положительного обзора. Например, если результат равен 0.85, это означает, что модель оценивает текст как положительный с вероятностью 85%. Если результат близок к 0, это означает, что текст скорее всего отрицательный, а если близок к 1, то текст скорее всего положительный.

Этот код создает простую модель CNN для анализа тональности текстов. Обратите внимание, что для реальных данных потребуется больше данных и тонкая настройка модели для достижения высокой точности.

### **– Обработка последовательностей:**

Сверточные нейронные сети (CNN), изначально разработанные для обработки изображений, также могут быть при-

менены к текстовым данным. Для этого текст обрабатывается как последовательность символов или слов, и каждый элемент последовательности (символ или слово) кодируется в числовой форме. Затем текст преобразуется в матрицу, где каждый столбец соответствует символу или слову, а строки – контекстным окнам (например, наборам слов или символов).

Давайте рассмотрим этот процесс более подробно:

**Кодирование текста:** Сначала текст кодируется в числовую форму. Это может быть выполнено с использованием токенизации, при которой каждому уникальному слову или символу назначается уникальное числовое значение (индекс). Эти числовые значения представляют слова или символы в числовой форме.

**Представление в виде матрицы:** Кодированный текст представляется в виде матрицы, где каждый столбец соответствует слову или символу, а строки представляют контекстные окна. Это означает, что каждая строка матрицы представляет собой последовательность слов или символов из исходного текста. Размерность матрицы зависит от размера контекстного окна и размера словаря (количество уникальных слов или символов).

**Сверточные слои:** Сверточные слои в CNN применяются к матрице, чтобы извлечь важные признаки из текста. Свертка происходит путем сканирования фильтров (ядер свертки) через матрицу. Эти фильтры могут выявлять различные шаблоны и особенности в тексте, такие как последователь-

ности слов или символов. Результатом свертки является новая матрица, называемая картой признаков (feature map).

Пулинг (Pooling): После применения сверточных слоев может выполняться операция пулинга. Пулинг используется для уменьшения размерности карты признаков, уменьшая количество параметров и улучшая обобщающую способность модели. Обычно используется операция максимального пулинга (MaxPooling), которая выделяет наибольшие значения из окна, перемещая его по карте признаков.

Полносвязные слои: После применения сверточных и пулинговых слоев информация передается в полносвязные слои для классификации или регрессии. Полносвязные слои работают с вектором признаков, полученным из карты признаков после операции пулинга.

Преимущество использования CNN для текстовых данных заключается в способности модели извлекать локальные и глобальные признаки из текста, что может улучшить способность модели к анализу и классификации текста. Этот метод также позволяет модели работать с последовательностями разной длины, благодаря использованию окон и пулинга.

Следующий код решает задачу бинарной классификации текстовых отзывов на положительные и отрицательные. Каждый отзыв имеет метку 1 (положительный) или 0 (отрицательный).

В результате выполнения этого кода:

1. Мы создаем модель сверточной нейронной сети (CNN),

которая способна анализировать тексты.

2. Загружаем обучающие данные в виде массива текстов ``texts`` и их меток ``labels``.

3. Создаем токенизатор для преобразования текстов в численные последовательности и приводим тексты к числовому представлению.

4. Выравниваем текстовые последовательности до максимальной длины ``max_sequence_length``, чтобы их можно было использовать в нейронной сети.

5. Создаем модель CNN, состоящую из слоев `Embedding`, `Conv1D`, `GlobalMaxPooling1D` и `Dense`.

6. Компилируем модель, используя оптимизатор `"adam"` и функцию потерь `"binary_crossentropy"`.

7. Обучаем модель на обучающих данных в течение 10 эпох.

8. Оцениваем модель на тестовых данных (4 отдельных отзывает).

Результаты этого кода включают в себя точность модели на тестовых данных, которая измеряет, насколько хорошо модель классифицирует новые отзывы как положительные или отрицательные. Вы увидите значение точности на тестовых данных в консоли после выполнения кода. Точность ближе к 1.0 означает, что модель хорошо обучена и способна правильно классифицировать тексты.

```
import tensorflow as tf
import numpy as np
```

```
import matplotlib.pyplot as plt
Генерируем примеры текстовых данных
texts = ["Это отличный продукт.", "Этот товар ужасен.",
"Мне нравится эта книга.", "Не советую этот фильм."]
labels = [1, 0, 1, 0] # 1 – положительный отзыв, 0 – отри-
цательный отзыв
Создаем токенизатор и преобразуем тексты в последо-
вательности чисел
tokenizer =
tf.keras.preprocessing.text.Tokenizer(num_words=1000,
oov_token("<OOV>"))
tokenizer.fit_on_texts(texts)
sequences = tokenizer.texts_to_sequences(texts)
Подготавливаем данные для CNN
max_sequence_length = max([len(seq) for seq in sequences])
padded_sequences =
tf.keras.preprocessing.sequence.pad_sequences(sequences,
maxlen=max_sequence_length)
Преобразуем метки в массив numpy
labels = np.array(labels)
Создаем модель CNN
model = tf.keras.Sequential([
tf.keras.layers.Embedding(input_dim=1000,
output_dim=16, input_length=max_sequence_length),
tf.keras.layers.Conv1D(128, 3, activation='relu'), # Умень-
шили размер ядра до 3
```

```
tf.keras.layers.GlobalMaxPooling1D(),
tf.keras.layers.Dense(1, activation='sigmoid')
])
Компилируем модель
model.compile(optimizer='adam',
loss='binary_crossentropy', metrics=['accuracy'])
Обучаем модель
history = model.fit(padded_sequences, labels, epochs=10,
verbose=1)
Оцениваем модель на тестовых данных
test_texts = ["Это лучшая книга.", "Не стоит тратить деньги.", "Мне понравился фильм.", "Ужасное качество товара."]
test_labels = [1, 0, 1, 0] # Метки для тестовых данных
test_sequences = tokenizer.texts_to_sequences(test_texts)
padded_test_sequences =
tf.keras.preprocessing.sequence.pad_sequences(test_sequences,
maxlen=max_sequence_length)
test_labels = np.array(test_labels)
test_loss, test_accuracy =
model.evaluate(padded_test_sequences, test_labels)
print(f"Точность на тестовых данных: {test_accuracy:.4f}")
Визуализация результатов
plt.figure(figsize=(12, 4))
plt.subplot(1, 2, 1)
plt.plot(history.history['accuracy'], label='Точность на обучении')
```

```
plt.xlabel('Эпохи')
plt.ylabel('Точность')
plt.legend()
plt.subplot(1, 2, 2)
plt.plot(history.history['loss'], label='Потери на обучении')
plt.xlabel('Эпохи')
plt.ylabel('Потери')
plt.legend()
plt.show()
```

На графиках, полученных после выполнения предоставленного кода, вы увидите результаты обучения и оценку модели. Давайте разберем подробнее:

1. График точности на обучении (Точность на обучении): Этот график показывает, как точность модели изменяется в течение эпох обучения. Точность на обучении измеряет, как хорошо модель предсказывает данные обучения. Вы ожидаете, что точность будет увеличиваться с каждой эпохой. Если точность растет, это может указывать на то, что модель успешно изучает данные.

2. График потерь на обучении (Потери на обучении): Этот график отражает, как уменьшается потеря модели на обучении с течением эпох. Потери представляют собой меру того, насколько сильно предсказания модели отличаются от фактических меток. Цель – минимизировать потери. Уменьшение потерь также указывает на успешное обучение модели.

На практике хорошо обученная модель будет иметь сле-

дующие характеристики:



- Точность на обучении растет и стабилизируется на определенном уровне.

- Потери на обучении уменьшаются и стабилизируются на низком уровне.

Если точность на тестовых данных также высока, это означает, что модель успешно обобщает знания на новые, ранее не виденные данные.

На графиках, представленных в коде, вы сможете оценить, как точность и потери меняются с течением эпох, и определить успешность обучения модели.

```
Epoch 1/10
1/1 [=====] - 3s 3s/step - loss: 0.6914 - accuracy: 0.5000
Epoch 2/10
1/1 [=====] - 0s 30ms/step - loss: 0.6857 - accuracy: 0.7500
Epoch 3/10
1/1 [=====] - 0s 25ms/step - loss: 0.6802 - accuracy: 1.0000
Epoch 4/10
1/1 [=====] - 0s 22ms/step - loss: 0.6750 - accuracy: 1.0000
Epoch 5/10
1/1 [=====] - 0s 17ms/step - loss: 0.6701 - accuracy: 1.0000
Epoch 6/10
1/1 [=====] - 0s 21ms/step - loss: 0.6653 - accuracy: 1.0000
Epoch 7/10
1/1 [=====] - 0s 19ms/step - loss: 0.6605 - accuracy: 1.0000
Epoch 8/10
1/1 [=====] - 0s 17ms/step - loss: 0.6556 - accuracy: 1.0000
Epoch 9/10
1/1 [=====] - 0s 17ms/step - loss: 0.6505 - accuracy: 1.0000
Epoch 10/10
1/1 [=====] - 0s 16ms/step - loss: 0.6453 - accuracy: 1.0000
1/1 [=====] - 0s 253ms/step - loss: 0.6844 - accuracy: 0.7500
Точность на тестовых данных: 0.7500
```



Кроме того, существуют более сложные архитектуры, которые комбинируют RNN и CNN, чтобы использовать преимущества обоих типов сетей. Например, архитектура под названием Transformer, изначально разработанная для машинного перевода, стала основой для многих современных моделей в NLP, таких как BERT и GPT.

Архитектура Transformer представляет собой мощный прорыв в области обработки естественного языка (NLP) и

обработки последовательностей в целом. Она представляет собой нейронную сеть, спроектированную специально для работы с последовательностями, и она имеет ряд ключевых особенностей:

1. Механизм внимания: Одной из ключевых особенностей Transformer является механизм внимания. Внимание позволяет модели фокусироваться на разных частях входных данных в зависимости от их важности. Это улучшает способность модели обрабатывать длинные последовательности и улавливать долгосрочные зависимости в данных.

2. Свёрточные и полносвязные слои: Transformer включает в себя свёрточные слои, которые работают с каждой позицией в последовательности независимо. Это позволяет модели извлекать локальные признаки из текста. Также в архитектуре есть полносвязные слои, которые обрабатывают информацию с учётом взаимодействия всех позиций в последовательности.

3. Многоуровневая структура: Transformer состоит из нескольких идентичных слоев, называемых "трансформерами", каждый из которых обрабатывает входные данные независимо. Это многоуровневое устройство позволяет модели извлекать признаки разной абстракции и работать с последовательностью на разных уровнях.

4. Многоголовое внимание: Transformer также использует многоголовое внимание (multi-head attention), что позволяет модели фокусироваться на разных аспектах входных данных

одновременно. Это способствует изучению различных типов зависимостей в данных.

5. **Позиционное кодирование:** Поскольку Transformer не имеет встроенной информации о позиции слова в последовательности (как у RNN), используется позиционное кодирование. Это позволяет модели учитывать позицию каждого элемента в последовательности.

Архитектура Transformer и её модификации (например, BERT и GPT) стали основой для многих современных задач в NLP, включая машинный перевод, обработку текста, анализ тональности, вопросно-ответные системы и многое другое. Эти модели показали выдающуюся производительность благодаря своей способности к обучению на больших объёмах данных и обобщению на различные задачи.

BERT (Bidirectional Encoder Representations from Transformers) и GPT (Generative Pre-trained Transformer) – это две мощные модели для работы с естественным языком (Natural Language Processing, NLP). Они используют архитектуры Transformer для различных задач NLP, но они имеют разные цели и способы использования. Давайте рассмотрим каждую из них с подробным описанием и примерами использования.

# Конец ознакомительного фрагмента.

Текст предоставлен ООО «Литрес».

Прочитайте эту книгу целиком, [купив полную легальную версию](#) на Литрес.

Безопасно оплатить книгу можно банковской картой Visa, MasterCard, Maestro, со счета мобильного телефона, с платежного терминала, в салоне МТС или Связной, через PayPal, WebMoney, Яндекс.Деньги, QIWI Кошелек, бонусными картами или другим удобным Вам способом.