УДК 004.852

ОБЗОР LSTM-НЕЙРОСЕТЕЙ: АРХИТЕКТУРА, РАЗВИТИЕ И ПРИМЕНЕНИЯ

Рубан Е.А. – студент 2 курс магистратуры, группа ИИм-241,
Кузбасский государственный технический университет имени Т.Ф. Горбачева
Россия, г. Кемерово

Последовательные данные являются одной из ключевых форм предоставления информации в современных задачах машинного обучения. К ним относится: текст, речь, музыкальные сигналы, биомедицинские временные ряды, данные от датчиков и многие другие источники. Классические рекуррентные нейронные сети (RNN) предназначены для работы с подобными структурами, но их обучение осложняется проблемой исчезающего и взрывающегося градиента, что ограничивает способность модели запоминать долгосрочные зависимости.

Данную задачу эффективно решает архитектура долгой краткосрочной памяти (Long short-term memory, LSTM) — специальный тип рекуррентных нейросетей, обладающий способностью выявлять и запоминать длительные зависимости. Эта технология была впервые предложена Зеппом Хохрайтером и Юргеном Шмидхубером в 1997 году, а впоследствии доработана и подробно описана в исследованиях других ученых. Цель данной обзорной статьи – представить ключевые особенности архитектуры LSTM, рассмотреть её основные модификации и сравнить возможности с альтернативными подходами, а также обозначить области актуального применения.

Давайте разберемся с устройством и механизмом функционирования LSTM. Любая рекуррентная нейронная сеть строится как последовательность повторяющихся блоков нейронной сети. В стандартной RNN каждый такой блок имеет элементарную конструкцию, к примеру, это может быть одиночный слой активации tanh (гиперболический тангенс). Архитектура LSTM тоже выглядит как цепочка, однако её модули существенно отличаются. Вместо одного слоя они включают четыре, и эти слои взаимодействуют по уникальной схеме.

Основной элемент LSTM — это состояние ячейки, или ячейка памяти (cell state), которое проходит сквозь всю последовательность практически без изменений, подвергаясь лишь нескольким линейным операциям. Благодаря этому информация способна сохраняться в ней на протяжении значительного периода. Контроль доступа к этому состоянию обеспечивают три вида ворот, которые решают, какую информацию оставить, какую стереть и какую передать дальше.

"Забывающий фильтр" (forget gate) — это сигмоидальный слой, который определяет, какую часть данных следует удалить из состояния ячейки. Он анализирует предыдущее скрытое состояние h_{t-1} и текущий входной вектор X_t,

выдавая для каждого элемента состояния c_{t-1} значение от 0 до 1. Здесь 1 обозначает полное сохранение, а 0 — полное удаление.

"Входной фильтр" (input gate) — сигмоидальный слой, отвечающий за выбор новой информации для добавления в состояние ячейки. Сначала он решает, какие компоненты стоит обновить. Далее tanh-слой генерирует вектор потенциальных новых значений $\tilde{C}_t$, которые могут быть интегрированы в состояние.

"Выходной фильтр" (output gate) — сигмоидальный слой, который определяет, какую информацию передать на выход. После этого состояние ячейки пропускается через tanh-слой для нормализации значений в диапазоне от -1 до 1, а затем умножается на результаты сигмоида, что обеспечивает вывод только релевантных данных.

Такая структура позволяет LSTM поддерживать стабильный поток градиентов во время обучения, благодаря чему модель способна эффективно запоминать зависимости на достаточно большое количество шагов назад.

С момента появления данной архитектуры было предложено множество ее вариаций, направленных на повышение эффективности и адаптацию под конкретные задачи.

Gated Recurrent Unit (GRU)- один из наиболее популярных вариантов, предложенный в 2014 году. GRU объединяет некоторые слои и упрощает структуру сети, что уменьшает число параметров и ускоряет обучение. GRU – демонстрирует сравнимую точность в ряде задач.

Peephole connections – позволяют вратам LSTM учитывать текущее состояние памяти напрямую, что улучшает способность модели хранить точные временные зависимости.

Двунаправленные LSTM (BiLSTM) – обрабатывают последовательность как с справа на лево, так и слева на право, что особенно важно в задачах обработки человеческого языка, где значение элемента зависит от контекста с обоих сторон.

Многослойные LSTM (Stacked LSTM) – позволяют модели захватывать закономерности разного уровня сложности.

Благодаря своей гибкости LSTM нашли широкое применение в самых разных областях.

1. Обработка текстов и речи - до появления трансформеров архитектуры на основе LSTM активно использовались в задачах машинного перевода, генерации текста, анализа тональности, распознавания речи. Модели такого типа позволяли достигать высоких результатов в конкурсах по NLP и сыграли важную роль в развитии отрасли.

2. Анализ временных рядов - LSTM широко применяются в экономике, финансах, энергетике и промышленности. Их способность моделировать долгосрочные зависимости делает их эффективными для прогнозирования спроса, анализа цен, предсказания состояния оборудования, а также для обработки биомедицинских сигналов (ECG, EEG), где требуется учитывать сложные закономерности.

3. Интеллектуальные системы и робототехника - архитектуры LSTM применяются для анализа сенсорных данных, предсказания траекторий, управления автономными устройствами. Их использование позволяет моделям учитывать предшествующее состояние среды, что важно для принятия решений в реальном времени.

4. Детекция аномалий- в задачах кибербезопасности, мониторинга систем и антифрода LSTM используются для выявления нетипичных последовательностей событий. Они эффективно распознают паттерны поведения, что делает их полезными при работе с логами, сетевыми пакетами или транзакциями.

Несмотря на преимущества, у LSTM есть ряд ограничений. Во-первых, обучение таких моделей требует значительных вычислительных ресурсов из-за большого количества параметров. Во-вторых, последовательная природа вычислений затрудняет параллелизацию, что замедляет обучение по сравнению с архитектурами, основанными на сверточных сетях или механизмах внимания.

На смену LSTM в задачах обработки языка пришли Transformers, опирающиеся на механизм самовнимания, который позволяет эффективно учитывать связи между любыми элементами последовательности. Эти модели лучше масштабируются и обеспечивают значительно более высокое качество.

Однако в задачах анализа временных рядов, малых данных и встроенных систем LSTM сохраняют актуальность благодаря своей устойчивости и меньшей требовательности к данным, чем трансформеры.

В заключении хотелось бы добавить, что архитектура LSTM сыграла важнейшую роль в развитии глубокого обучения и стала фундаментальной основой для работы с последовательностями. Несмотря на появление новых и более мощных моделей, LSTM остаются востребованными во многих прикладных областях, особенно там, где требуется моделирование временной динамики и учет долгосрочных зависимостей.

Продолжающееся развитие гибридных подходов, включающих механизмы внимания или комбинацию рекуррентных и сверточных моделей, подтверждает, что LSTM продолжают оставаться значимым инструментом в арсенале исследователей и инженеров. Их историческое и практическое значение делает их одной из ключевых архитектур, сформировавших современное направление машинного обучения.

Список литературы:

1. Гудфеллоу И., Бенджио Й., Курвилль А. Глубокое обучение [текст]. — М.: ДМК Пресс, 2018. — 796 с.

2. Olah C. Understanding LSTM Networks [электронный ресурс]. — 2015. — URL: https://colah.github.io/posts/2015-08-Understanding-LSTMs/ (дата обращения: 18.11.2025).