

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ LSTM ДЛЯ ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ

В данной статье рассматривается возможность применения нейронных сетей LSTM при прогнозировании временных рядов. Проводится обучение нейронной сети на основе реальных значений, полученных опытным путем.

Вопрос прогнозирования некоторых событий всегда был актуален. Во всех сферах создавались свои дисциплины и направления, основная задача которых сводилась к некоторому прогнозированию состояния. В каждой сфере были выявлены свои закономерности, выведено множество формул, были выявлены основные взаимосвязи и последствия тех или иных решений. Большая их часть стоит на большом объеме теоретического материала, проверенного временем.

Тем не менее у существующих методов прогнозирования есть альтернативы.

В данной статье предлагается рассмотреть возможность применения нейронных сетей и науки о данных для прогнозирования временных рядов.

С целью изучения возможности прогнозирования временных рядов нейронные сети LSTM. По своей сути они представляют из себя рекуррентные нейронные сети, которые могут сохранять предыдущие значения, которые, в свою очередь, могут влиять на последующее прогнозирование. Для лучшего понимания сущности LSTM следует рассмотреть понятие рекуррентные нейронных сети, как они строятся и почему они необходимы в прогнозировании.

Рекуррентные нейронные сети (RNN) – это нейронные сети, включающие в себя некоторую последовательность модулей, способных так же последовательно обрабатывать исходные данные. Задача рекуррентных нейронных сетей сводится к тому, чтобы при последовательной обработке исходных данных требовалось учесть не только отклик каждого модуля, но и учитывалась связь между модулями. У данной сети есть одна особенность, отличающая её от персептронов. Это возможность запоминать предыдущие значения и передавать предыдущие значения как следующему слою, так и самому себе на следующий шаг. Реализация таких действий возможна благодаря наличию вектора, который запоминает предыдущие значения.

На рисунке 1 схематично представлена рекуррентная нейронная сеть.

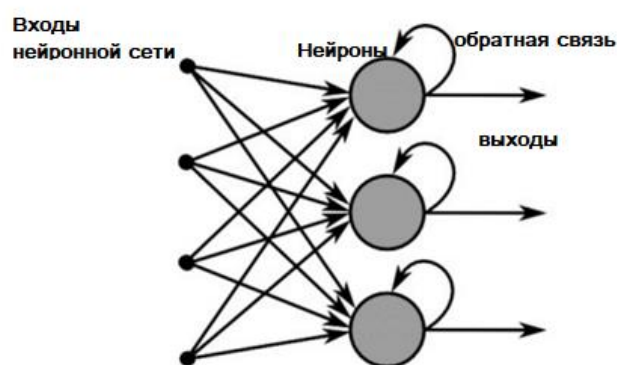


Рисунок 1 – Рекуррентная нейронная сеть

В настоящее время рекуррентные нейронные сети применяются в следующих областях:

- машинный перевод текста (как во многих онлайн переводчиках);
- преобразование речи в текст;
- прогнозирование рынка;
- вождение машины (можно комбинировать со свёрточной нейронной сетью).

Главными плюсами подобных систем являются:

- RNN запоминает каждую часть информации с течением времени, что полезно для прогнозирования временных рядов, это называется долговременной и кратковременной памятью;

- RNN используются даже со сверточными слоями для расширения эффективной окрестности пикселей.

Тем не менее, у подобной системы полно недостатков. В первую очередь:

- из-за повторяющейся природы вычисления медленные;
- обучение моделей рекуррентных нейронных сетей может быть сложным;
- невозможность запоминать данные на длительном периоде.

В целях данной статьи рассматриваем переход к LSTM, обращая внимание на 3 пункт, фактически именно он лежит в основе появления сетей LSTM. Нужно понимать, что возможность запоминать некоторую информацию на некоторый промежуток времени является достаточно относительной.

Подобные нейронные сети хотя и могут запоминать данные на короткие промежутки, на длинных промежутках связи могут теряться. Применение сети LSTM при прогнозировании некоторых временных рядов должно основываться на исправлении данной проблемы.

LSTM имеют цепную структуру, но повторяющий модуль имеет другое строение. Каждый блок LSTM состоит из трех основных компонентов:

- входной вектор – это входные данные, которые поступают на вход блока LSTM;

- скрытое состояние – это состояние блока LSTM, которое передается от одного блока к другому в последовательности данных;

- клеточное состояние – это состояние блока LSTM, которое хранит информацию о предыдущих значениях и может обновляться или забываться.

Каждый блок LSTM имеет четыре основные функции:

- функция забывания определяет, какая информация должна быть забыта из клеточного состояния;

- функция входа определяет, какая информация должна быть добавлена в клеточное состояние;

- функция выхода определяет, какая информация должна быть передана в скрытое состояние;

- функция активации определяет, какая информация должна быть передана на выходной слой.

Компоненты LSTM взаимодействуют между собой следующим образом:

1. Входной вектор поступает на вход блока LSTM и передается в функцию входа, которая определяет, какая информация должна быть добавлена в клеточное состояние.

2. Клеточное состояние передается в функцию забывания, которая опреде-

ляет, какая информация должна быть забыта из клеточного состояния.

3. Результат функции забывания передается в функцию входа, которая определяет, какая информация должна быть добавлена в клеточное состояние.

4. Результат функции входа и предыдущее значение скрытого состояния передаются в функцию выхода, которая определяет, какая информация должна быть передана в скрытое состояние.

5. Результат функции выхода передается в функцию активации, которая определяет, какая информация должна быть передана на выходной слой.

6. Скрытое состояние передается от одного блока LSTM к другому в последовательности данных, чтобы сохранять контекст и память о предыдущих значениях.

Таким образом, блок LSTM может обрабатывать последовательности данных, сохраняя информацию на длительное время и забывая неактуальную информацию.

Описание данных

В качестве экспериментальных данных для прогнозирования в данной статье будут использоваться данные полученные на промышленном предприятии г. Бреста.

Таблица 1 – Данные для прогнозирования

shid	Описание	Размерность
1	(мощность), циркуляционный насос	0–100 (0 – минимальная мощность, 100 – максимальная мощность)
2	расход	м ³ /час
3	температура гомогенизации	°С
4	(степень открытия), паровой клапан	0–100 (0 – полностью закрыт, 100 – полностью открыт)
5	температура пастеризации	°С
6	(степень открытия), паровой клапан	0–100 (0 – полностью закрыт, 100 – полностью открыт)

Все данные представляют собой временные ряды некоторых процессов, что были сняты в результате работы некоторых агрегатов. Все данные различного характера и назначения, что позволяет говорить о некоторой репрезентативности выборки. Из этого следует, что результаты данной статьи могут являться масштабируемыми во всех отраслях, где применяются временные ряды.

Применение методики и оценка

Для данной модели используется язык программирования python и библиотеки keras для создания и обучения сети LSTM для дальнейшего прогнозирования. Помимо этого, понадобится IDE для работы с языком python, а так же, желательно, компьютер с объемом оперативной памяти больше 4 Гб. Указав необходимый файл, нейронная сеть изначально считывает его, после чего приступает к обучению, а позже прогнозированию.

На графиках, представленных в статье, присутствуют графики трех цветов:

1. Синего – реальные данные, что были сняты во время работы установки и которые мы будем считать реальными или эталонными.

2. Оранжевого – обучающая выборка, т. е. данные, на которых обучалась нейронная сеть для успешного прогнозирования.

3. Зелёного – предсказанные данные, т. е. те данные, что выдала сама сеть и которые мы сравниваем с эталонными (реальными) значениями, полученными в ходе реальной работы.




Рисунок 2 – степень открытия парового клапана под сидом 4

На рисунке 2 представлен график открытия парового клапана, который в таблице представлен под сидом 4. На данном графике 100 – клапан открыт полностью, 0 – клапан закрыт.




Рисунок 3 – Температура пастеризации (пастеризационной установки)

На рисунке 3 представлен график температуры пастеризации, который в таблице представлен под сидом 5.




Рисунок 4 – степень открытия парового клапана под сидом 4

На рисунке 4 представлен график открытия парового клапана, который в таблице представлен под сидом 6. На данном графике 100 – клапан открыт полностью, 0 – клапан закрыт.

По приведенным выше примерам можно проследить предсказательную силу модели.

В частности, совпадение на уровне зелёных данных. Модель можно считать успешной, если отклонение от эталонных данных полученных опытным путем, является допустимым или отсутствует вовсе. Можно заметить, что графики предсказанных значений во многом повторяет эталонные значения, полученные в ходе реальной эксплуатации объекта.

Представленный подход к прогнозированию является корректным и говорит о том, что нейронная сеть может правильно предсказывать значения некоторой последовательности.

Исходя из полученных графиков, можно констатировать, что нейронная сеть правильно предсказывает значения с относительно небольшой погрешностью.

Вывод

Нейронная сеть на модели LSTM показывает свою эффективность при прогнозировании больших временных рядов. Однако для более успешного прогнозирования необходима ещё большая и разнообразная выборка. Это поможет «настроиться» нейронной сети на выдачу необходимого результата.

Список цитированных источников

1. Постолиит А. В Основы искусственного интеллекта в примерах на Python. Самоучитель / А. В. Постолиит – СПб. : БХВ-Петербург, 2022. – 448 с.
2. Хайндман, Р. Прогнозирование: принципы и практика / Р. Хардман, Д. Атанасопулос, пер. с англ. А. В. Логунова – М. : ДМК Пресс, 2023. – 458 с.
3. Грас, Д. Data Science. Наука о данных с нуля: пер. с англ. / Д. Грас – 2-е изд., перераб. и доп. – СПб. : БХВ-Петербург, 2023. – 416 с.: ил.
4. Глубокое обучение для детектирования объектов на изображениях документов [Электронный ресурс] / А. А. Крощенко [и др.] // Вестник Брестского государственного технического университета. – 2017. – № 5. Физика, математика, информатика – С. 2–9.
5. Long Short-Term Memory [Электронный ресурс] / Й. Хохрайтер, Ю. Шмидхубер. – Режим доступа: <https://www.bioinf.jku.at/publications/older/2604.pdf>. – Дата доступа: 06.05.2023.