

Прогнозирование концентрации метана в рабочей зоне угольной шахты на основе рекуррентных нейронных сетей

Д. М. Бузмаков, А. В. Кашников

Горный институт Уральского отделения РАН

Пермь, Россия

Dima27011999@yandex.ru, alexey.kashnikov@gmail.com

Аннотация. Данная работа описывает модель прогноза содержания метана в атмосфере рабочей зоны угольной шахты. Рассмотрены конкретные предприятия, а именно шахты по добыче угля. На таких производствах особое внимание уделяется безопасности. Самым опасным фактором при добыче угля является выделение метана. Так как метан в большой концентрации является взрывоопасным, в горных выработках находятся датчики, которые следят за его процентным содержанием в воздухе. Изменение данного параметра необходимо прогнозировать для того, чтобы максимизировать объем добытого угля и минимизировать риск аварии.

Ключевые слова: *искусственный интеллект; метан; угольная шахта; рекуррентная нейронная сеть; прогнозирование временных рядов*

I. ВВЕДЕНИЕ

Прогнозирование временных рядов – довольно частая тема исследований, однако на сегодняшний день успешные модели прогнозирования опираются на регрессионный анализ данных и на так называемый «метод скользящего окна». Данные модели работают стабильно и с большой точностью лишь в тех случаях, когда имеются данные о всех факторах, которые оказывают непосредственное влияние на изучаемую величину. К сожалению, на реальном производстве не всегда можно измерить нужные данные. Поэтому будет рассматриваться случай, когда мы имеем данные лишь о косвенных признаках, которые влияют на концентрацию метана в атмосфере рабочей зоны угольной шахты.

Существующие системы широко распространены и в основном используются для планирования и оценки эффективности работ горных предприятий. Такие ИС предназначены для более общих целей, что не гарантирует точное прогнозирование содержания метана в рамках одной конкретной шахты. [1]

II. ВЫБОР МОДЕЛИ

Так как зависимость между входными и выходными параметрами достаточно сложно оценить на основе реальных данных с приборов, было решено реализовать модель в виде модели нейронной сети.

Нейронные сети (искусственная нейронная сеть) — это система соединенных и взаимодействующих между собой простых процессоров (искусственных нейронов). Каждый процессор подобной сети имеет дело только с сигналами, которые он периодически получает и посылает другим процессорам. И, тем не менее, будучи соединёнными в достаточно большую сеть с управляемым взаимодействием, эти процессоры вместе способны выполнять довольно сложные задачи, поскольку нейронные сети обучаются в процессе работы. [2]

Мы имеем дело с непрерывным по времени фрагментом данных. Особое влияние оказывает тот факт, что после разрушения массива метан продолжает выделяться с обнаженного угольного пласта. [3] Отсюда следует, что нам необходимо учитывать результаты в предыдущие моменты времени.

Существует большое количество различных моделей нейронных сетей: однослойный и многослойный перцептрон, свёрточные нейронные сети и многие другие. В качестве рабочей модели была выбрана рекуррентная нейронная сеть, так как рекуррентные нейронные сети имеют свойство оценивать предыдущие полученные значения для получения новых значений. Оценивая временные ряды, не сложно понять, что на значения в определённый момент времени влияют не только входные параметры, полученные на данный момент, но и параметры, которые были получены несколько временных промежутков ранее. Особенно это важно при прогнозе выделения метана из горных пород. [4]

Разработка сети велась с помощью таких инструментов, как Keras, Tensorflow, KNIME. [5]

III. ОБРАБОТКА ДАННЫХ

Учитывая то, что данные были получены в разреженном виде, а также они были не нормализованы, обработке данных было отведено большое значение. С помощью регрессионного анализа различные доступные параметры были исследованы на предмет влияния их на контрольное содержание метана. После чего были выделены следующие ведущие показатели:

- сила тока, потребляемая режущими органами комбайна;

- мощность, потребляемая лавным конвейером;
- расход воздуха, зафиксированный на всех датчиках дегазационных установок;
- расход воздуха, зафиксированный на датчике в забое;
- содержание метана, зафиксированное на датчике в забое.

После этого данные были нормализованы, профильтрованы и преобразованы к нужному виду для подачи на вход рекуррентной нейронной сети.

IV. РАЗЛИЧНЫЕ МОДЕЛИ

Вся разработка модели происходила с помощью стандартных возможностей открытой нейросетевой библиотеки Keras.

A. Однослойный перцептрон

Начнём построение различных моделей с самой простой – перцептрона с одним скрытым слоем.

Первый слой имеет 8 нейронов для входных параметров, второй слой 30 нейронов, которые изначально инициализируются нулями, и функцию активации гиперболического тангенса:

$$th(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}.$$

Последний слой во всем повторяет второй, за исключением количества нейронов. Так как мы предсказываем лишь одно значение, на выходном слое один нейрон. Все эти параметры были подобраны экспериментальным способом, именно при таких параметрах показатель ошибки наименьший. Само же ядро нейронной сети имеет оптимизатор Adam и количество эпох равно 40, а все остальные параметры взяты по умолчанию.

Данная модель нейронной сети получила результаты моделирования, приведенные на рис. 1. Результат получился неудовлетворительный, но после анализа различных графиков было установлено, что графики предсказанных значений в общем случае сдвинуты на несколько минут назад. Это побудило рассмотреть следующий вид нейронных сетей.




Рис. 1. Графики реального содержания метана (красный) и предсказанного значения (синий)

B. Многослойный перцептрон

В данной модели был применён «метод скользящего окна». В качестве входных данных были добавлены 5 предыдущих входных параметров. Также добавлен ещё один скрытый слой. Такая структура нейронной сети дала более положительные результаты. Они представлены на рис. 2.




Рис. 2. Графики реального содержания метана (красный) и предсказанного значения (синий)

C. Рекуррентная нейронная сеть

Модель нейронной сети представляет из себя входной слой, скрытый рекуррентный слой Simple RNN, и один выходной слой. Simple RNN – простой слой рекуррентной сети, который способен предсказывать значение, основываясь лишь на нескольких непосредственно предшествующих данных. [6] Его схема представлена на рис. 3. Активационной функцией везде выступал гиперболический тангенс. Самые лучшие результаты были получены при анализе 15 предыдущих минут для текущего значения. Результат обучения нейронной сети представлен на рис. 4.




Рис. 3. Схема простой рекуррентной нейронной сети




Рис. 4. Графики реального содержания метана (красный) и предсказанного RNN значения на основе пятнадцати предыдущих данных (синий)

В результате получившаяся модель оценивает значение метана с точностью 67%. Данная модель имеет множество различных вариантов доработки. При увеличении интервала обучения, точность модели уменьшается. Это связано в большой степени с тем, что исходные данные имеют некоторые интервалы отсутствующих значений. Неполнота данных может быть связана с различными рода техническими проблемами на производстве. Поэтому интервал для обучения был выбран с наибольшим количеством имеющихся значений. Также для нахождения

минимума функции и избегания попадания в локальные экстремумы был применён приём случайных весов нейронов для нахождения самых благоприятных начальных значений, что привело к необходимости несколько раз обучать нейронную сеть в ожидании наилучшего результата. В итоге нейронная сеть дала точность: 70 %. Результаты представлены на рис. 5.




Рис. 5. Графики реального содержания метана (красный) и предсказанного RNN значения (синий) с использованием случайной инициализации нейронов

Если сравнить данный график с предыдущим, то можно заметить, что многие из пиков не совсем точно совпадают.

D. Глубокая нейронная сеть

Также в качестве эксперимента для сравнения была построена глубокая нейронная сеть.

Глубокое обучение – совокупность широкого семейства методов машинного обучения, основанных на имитации работы человеческого мозга в процессе обработки данных и создания паттернов, используемых для принятия решений. Как правило, глубокое обучение предназначено для работы с большими объемами данных и использует сложные алгоритмы для обучения модели. На больших наборах данных глубокое обучение показывает более высокую точность результатов в сравнении с традиционным машинным обучением. [7]

К сожалению, в нашем случае мы имеем не совсем большой набор корректных данных – поминутные значения за двое суток.

Было решено объединить рассмотренные ранее модели. Таким образом, результирующая нейронная сеть была представлена двумя скрытыми слоями: рекуррентным слоем и стандартным слоем активации. Функцией активации все также являлся гиперболический тангенс, анализ производился на основе пятнадцати предыдущих значений.

Добавление дополнительных слоёв не дало улучшения результата. К тому же проектирование глубокой нейронной сети с большим количеством слоев стало трудоёмким. С добавлением каждого нового слоя, количество возможных различных настроек нейронной сети увеличивалось экспоненциально. На основе этих причин было принято решение, остановиться на двух скрытых слоях. Результат данной модели представлен на рис. 6.




Рис. 6. Графики реального содержания метана (красный) и предсказанного RNN значения (синий) с использованием глубокой нейронной сети

Глубокие нейронные сети подходят лишь для определённого круга задач. Как видно из графика, эксперимент привел к ухудшению точности модели, поэтому использование глубоких нейронных сетей для данной задачи было отклонено.

V. ЗАКЛЮЧЕНИЕ

Таким образом, самый лучший результат был получен с помощью нейронной сети с одним скрытым рекуррентным слоем, при начальной инициализации нейронов нулевыми значениями. Такая модель дала результат значительно лучше, чем остальные модели нейронных сетей. Поэтому для предсказания временных рядов было решено использовать именно её. Хотя стоит отметить, что для некоторых конкретных задач при анализе временных рядов глубокие нейронные сети дают удовлетворительный результат.

В дальнейшем планируется разработать систему управления комбайном на основе данных, предсказанных текущей нейронной сетью, а также разработать модуль уже существующей системы для моделирования ситуаций, возникающих в атмосфере рабочей зоны угольной шахты.

СПИСОК ЛИТЕРАТУРЫ

- [1] Журавлев Е.И. Разработка геоинформационной системы прогнозирования динамических проявлений в углевещающем массиве при подземной разработке угольных месторождений [Электронный ресурс] URL: <https://mis.ru/files/3494/zuravlev-diss.pdf> (дата обращения: 30.03.2020).
- [2] Николаенко С., Кадулин А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. СПб: Питер, 2018.
- [3] Скрицкий В.А. Причины взрывов метана в высокопроизводительных угольных шахтах Кузбасса. // Инноватика и экспертиза. 2017. Выпуск 2 (20).
- [4] Анализ временных рядов и прогнозирование. / Под ред. Садовникова Н.А., Шмойлова Р.А.: Издательский дом Университета "Синергия", 2016.
- [5] Сардарова М. Д. Обзор аналитической платформы KNIME. // Молодежный научно-технический вестник # 06, июнь 2015
- [6] Бендерская Е.Н., Никитин К.В. Рекуррентная нейронная сеть как динамическая система и подходы к ее обучению. / Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика, телекоммуникации и управление, 2013.
- [7] Morgan Nelson; Bourlard Hervé; Renals, Steve; Cohen Michael; Franco Horacio. Hybrid neural network/hidden markov model systems for continuous speech recognition // International Journal of Pattern Recognition and Artificial Intelligence. 1993-08-01. № 07 (4): 899–916.