

УДК 004.852

Прогнозирование рекуррентной нейронной сетью технологических ремонтных операций нефтяных скважин

Карамова Э.Р., Еникеев М.Р.

Уфимский государственный нефтяной технический университет

В процессе использования нефтяных скважин существует возможность возникновения тех или иных неполадок, связанных как непосредственно со скважинами, так и с соответствующим подземным оборудованием. Для предупреждения возникновения неисправностей, способных привести к нарушениям и выводу скважины из эксплуатации, следует предпринимать соответствующие меры. Ремонт нефтяных скважин заключается в выполнении мероприятий по предупреждению и устранению неполадок работы скважин.

Каждый вид ремонта включает в себя операции, проводимые с целью поддержания скважины в состоянии полной работоспособности. Последовательность операций регламентирована и имеет неизменяемую структуру согласно плану ГТМ (геолого-технических мероприятий). Вследствие этого, выбрав любую последовательность из N ремонтных операций, можно на ее основе определить следующую $N + 1$ ремонтную операцию, как человеком, так и нейронной сетью.

В работе рассматривается задача применения рекуррентной нейронной сети вида LSTM (Long short-term memory) для предсказания следующей ремонтной операции на основе последовательности предыдущих операций (рис. 1).

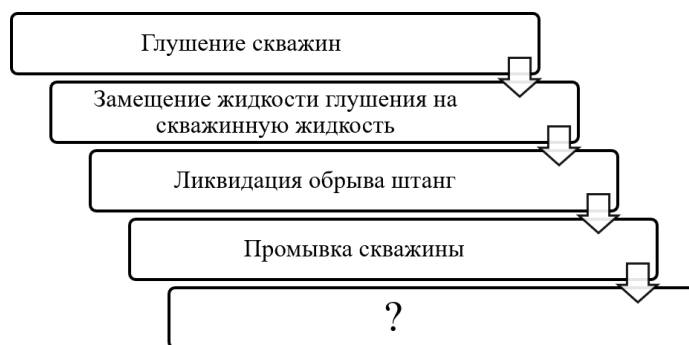


Рис. 1. Предсказание следующей операции на основе последовательности.

Процесс получения значения точности предсказания $N + 1$ ремонтной операции состоит из трех этапов: подготовки данных для обучения, создание архитектуры нейронной сети и оценка построенной сети на тестовых данных.

Подготовка данных. В данном исследовании рассматривалась сводка по ремонтным операциям на скважинах, статистика по которым была собрана за годовой период времени.

Данные по ремонтным операциям были отсортированы, перекодированы из текстового в численное представление, т.е. каждая операция имела свой уникальный идентификатор, и разбиты на массивы, содержащие последовательности длиной по 5 элементов. Всего было получено 400 000 последовательностей, содержащих 596 видов ремонтных операций.

Набор данных, состоящий из 400000 элементов был разделен на две части — тренировочная часть составляла 70% от всей выборки, тестовая часть 30%. Необходимость такого подхода вызвана следующим фактом: после того, как модель была обучена на тренировочных экземплярах, необходимо проверить результаты и эффективность её работы на тестовых образцах, которых ещё не было в наборе данных, на которых модель обучалась для оценки точности сети.

Создание нейронной сети. Для достижения поставленной цели была выбрана разновидность рекуррентной нейронной сети с долгой краткосрочной памятью – LSTM (Long short-term memory Neural Network), которая содержит обратные связи и позволяет сохранять информацию. При этом под обратной связью подразумевается связь от логически более удалённого элемента к менее удалённому элементу. Сеть способна обучаться на длинных последовательностях входных данных и запоминать их.

Рисунок 2 иллюстрирует архитектуру построенной сети LSTM для данной задачи: первый embedding-слой нейронной сети создает словарь, отображающий целочисленные индексы в плотные векторы, второй и третий lstm-слои добавляют поддержку переноса информации через многие интервалы времени, заканчивается сеть двумя полносвязными dense-слоем для предсказания.

Layer (type)	Output Shape	Param #
embedding (Embedding)	(None, 4, 32)	19072
lstm (LSTM)	(None, 4, 32)	8320
lstm_1 (LSTM)	(None, 32)	8320
dense (Dense)	(None, 1024)	33792
dense_1 (Dense)	(None, 596)	610900
Total params: 680,404		
Trainable params: 680,404		

Рис. 2. Структура нейронной сети.

Оценка нейронной сети на тестовых данных. Оценка рекуррентной сети LSTM на тестовых данных осуществлялась на четырех элементах каждой последовательности, принятых за x , выводила прогноз пятого элемента, который сравнивала с пятым действительным элементом последовательности, принятого за y . Если предсказанное значение совпадало с действительным, то значение точности увеличивалось. Схема работы алгоритма приведена на рисунке 3.

$$\begin{aligned}
 x_{test} &= [x_1, x_2, x_3, x_4] \\
 y_{test} &= [y] \\
 [x_1, x_2, x_3, x_4] &\xrightarrow{\text{predict}} x_5 \xrightarrow{\text{compare with } y_{test}} \text{accuracy}
 \end{aligned}$$

Рис. 3. Механизм предсказания $N + 1$ элемента последовательности.

В результате работы такого алгоритма была получена точность предсказания операции технологического ремонтного процесса нефтяной скважины с помощью нейронной сети на

основе LSTM равная 50%. Это означает, что созданная нейронная сеть справилась с поставленной задачей, но требует изменения параметров нейронной сети для достижения лучших результатов.

Литература

1. Шолле Ф. Глубокое обучение на Python. СПб.: Питер, 2018. С. 155-205.
2. Тарик Р. Создаем нейронную сеть. СПб.: Питер, 2016. С. 129–198.
3. Moolayil J. Learn Keras for Deep Neural Networks. Vancouver, Canada, 2019. С. 162-167.
4. Understanding LSTM Networks [Electronic resource]. URL:
<http://people.idsia.ch/~juergen/rnn.html>
5. Nal Kalchbrenner Grid Long Short-Term Memory [Electronic resource]. URL:
<https://arxiv.org/pdf/1507.01526v1.pdf>

MSC2020 68T05

Predicting of oil well technological repair operations by a neural network

E. R. Karamova, M. R. Enikeev
Ufa State Petroleum Technological University