

ПРОГНОЗИРОВАНИЕ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ЭЛЕКТРОЦЕНТРОБЕЖНОГО НАСОСА НА ОСНОВЕ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ

И.В. Каракулов, А.В. Клюев, В.Ю. Столбов

*Пермский национальный исследовательский политехнический университет,
г. Пермь, Россия*

Введение. Рассматривается задача прогнозирования состояния электроприводного центробежного насоса в процессе эксплуатации. Простои и недоборы, вызванные поломкой насоса, приводят к потерям при добыче нефти и требуют времени для замены оборудования. При помощи прогнозирования технического состояния появляется возможность минимизировать затраты на обслуживание насоса и сократить время простоя скважины. Для анализа состояния систем используют экспертные системы, основанные на знаниях, и методы предиктивной аналитики, основным из которых является использование моделей машинного обучения. В работе используются методы, основанные на искусственных нейронных сетях. **Цель исследования.** Проработка вопросов возможности прогнозирования технического состояния насоса за счет использования современных моделей машинного обучения. **Материалы и методы.** Прогнозирование технического состояния оборудования осуществляется при помощи анализа временных рядов. Данные получены с телеметрических датчиков системы мониторинга, установленных на электроцентробежном насосе. Исходные данные снимались с интервалом в одну минуту. Была осуществлена предобработка исходных данных. Данные были очищены от пиков, которые явно выбиваются из нормального режима работы, и убраны периоды простоя скважины, на которых фазное напряжение равнялось нулю. Для прогнозирования временных рядов используется искусственная нейронная сеть с типом нейронов LSTM. Прогнозирование временного ряда осуществлялось на пять дней. Оценка параметров системы на длительные периоды времени позволяет оценить состояние ее компонентов и предотвращать поломку оборудования. **Результаты.** Исследованы возможности нейросетей, обученных на основе данных телеметрических датчиков системы мониторинга, предсказывать значения вертикальной вибрации насоса. Обосновано применение нейросетевой модели в виде LSTM, показавшей хорошие результаты при анализе временных рядов. Выявлено, что нейросети хорошо улавливают тренд внутри временного ряда, что говорит о возможности их применения совместно с экспертной системой. **Заключение.** Предложенные методы и модели апробированы на реальных данных, что подтверждает возможность их использования при разработке интеллектуальной информационной системы управления техническим состоянием электроцентробежного насоса в процессе эксплуатации.

Ключевые слова: электроприводный центробежный насос, прогнозирование, временные ряды, искусственная нейронная сеть, оценка точности прогнозирования, LSTM сеть.

Введение

Нефтяные месторождения часто находятся в труднодоступных местах. В настоящее время при каждой поломке нефтедобывающей установки требуется сформировать и отправить на объект ремонтную группу, которая на месте проводит анализ поломки и производит ремонт. Каждая поломка оборудования приводит к простоям нефтедобывающей установки, что влечет за собой значительные убытки и нарушение поставок продукта.

Для уменьшения простоев, вызванных поломкой оборудования, требуется непрерывный мониторинг состояния оборудования. Главной задачей является выявление неполадок в нефтедобывающем оборудовании до момента аварии. Это позволит сэкономить время на отправку ремонтной группы, которая сможет предотвратить будущую аварию. При этом важно сократить число ошибок, чтобы в будущем избежать ситуаций, при которых ремонтная группа была отправлена на объект, а оборудование работает исправно.

Одной из главных частей нефтедобывающей установки является электроприводный центробежный насос (ЭЦН). Ремонт ЭЦН – долгий процесс, который включает в себя поднятие насоса

на поверхность, ремонт и погружение обратно в скважину. На каждом ЭЦН используются датчики контроля. Датчики снимают различные показатели, такие как давление, температура, вибрация, сила тока и т. п. При анализе данных, полученных при помощи датчиков, можно спрогнозировать состояние системы и диагностировать будущую поломку. Например, как отмечено в [1], на исследуемом месторождении производится круглосуточное наблюдение в режиме реального времени за работой ЭЦН, что способствует увеличению срока службы оборудования. Увеличение срока службы достигается за счет предотвращения неправильного использования насоса и отслеживания чрезмерных нагрузок.

Для автоматизированной оценки состояния узлов ЭЦН используются экспертные системы основанные на знаниях и нечеткой логике [2–5]. Известные экспертные системы используют продукционную модель представления знаний, что позволяет прогнозировать отказ ЭЦН и определять причины, из-за которых произошла поломка, за счет получения и сопоставления трендов, полученных с участков временного ряда значений измеряемых параметров функционирования оборудования, с определенным набором правил для допустимых изменений этих параметров. Основной трудностью при разработке подобных информационных систем является формирование актуальной базы знаний, основанной на опыте экспертов и данных о прошедших поломках.

В настоящее время в мире бурно развиваются методы ИИ, включая предиктивную аналитику [6, 7], основанную на глубокой обработке данных (data mining) с помощью машинного обучения и нейросетевых технологий. Однако известны лишь единичные случаи внедрения методов ИИ в нефтегазовой отрасли. Например, как отмечено в [8], норвежская нефтяная компания Equinor в 2018 г. сообщила о создании Центра сбора и обработки данных для улучшения процесса принятия управленческих решений.

В создании подобных интеллектуальных информационных систем (ИИС) заинтересованы и многие крупные российские нефтегазовые компании. Однако для разработки и внедрения ИИС в практику нефтедобычи необходимо проработать вопросы применимости существующих методов ИИ и, в случае положительного результата исследований, разработать на их базе модели, способные по информации, поступающей с оборудования в режиме реального времени, определять его техническое состояние и предсказывать возможные поломки узлов и отказы в ближайшем будущем. Для построения подобных моделей, основанных, например, на нейросетевых технологиях, необходимы большие массивы данных, полученных с датчиков за длительный период времени эксплуатации, а также сведения о произошедших поломках и проведенных ремонтах оборудования. Кроме того, для выявления возможных аномалий в работе оборудования, необходимо с помощью экспертов накопить необходимые знания, на основе которых можно сформировать критерии наступления различных аномалий по многофакторному анализу данных, поступающих с датчиков за определенный период.

Поэтому **целью** настоящей работы является проработка вопросов применения методов искусственного интеллекта для оценки технического состояния узлов электроцентробежных насосов на основе глубокой обработки текущих данных с помощью нейросетевых технологий.

Обработка исходных данных

Для анализа состояния ЭЦН был получен массив данных с одной из нефтедобывающих платформ, расположенной на шельфе Печерского моря. Изучались данные, полученные с добывающих скважин, каждая из которых характеризуется следующим набором технологических параметров: значение (для каждой фазы) трехфазного напряжения электропитания, В; ток электродвигателя, А; забойное давление на кровлю пласта, МПа; давление на приеме насоса, МПа; давление на выкиде насоса, МПа; давление в затрубном пространстве, МПа; давление на устье скважины, МПа; температура на приеме насоса, °С; температура на выкиде насоса, °С; температура электродвигателя, °С; вибрация насоса по оси X , м/с^2 ; вибрация насоса по оси Y , м/с^2 .

Источником информации по всем перечисленным параметрам являются телеметрические датчики системы мониторинга, сигналы от которых фиксируются в виде поминутных значений.

В качестве примера анализа временных рядов рассмотрим данные вибрации насоса по оси Y . На рис. 1 представлен временной ряд, по оси абсцисс которого размещены даты получения данных, а по оси ординат – значения показателя вибрации.

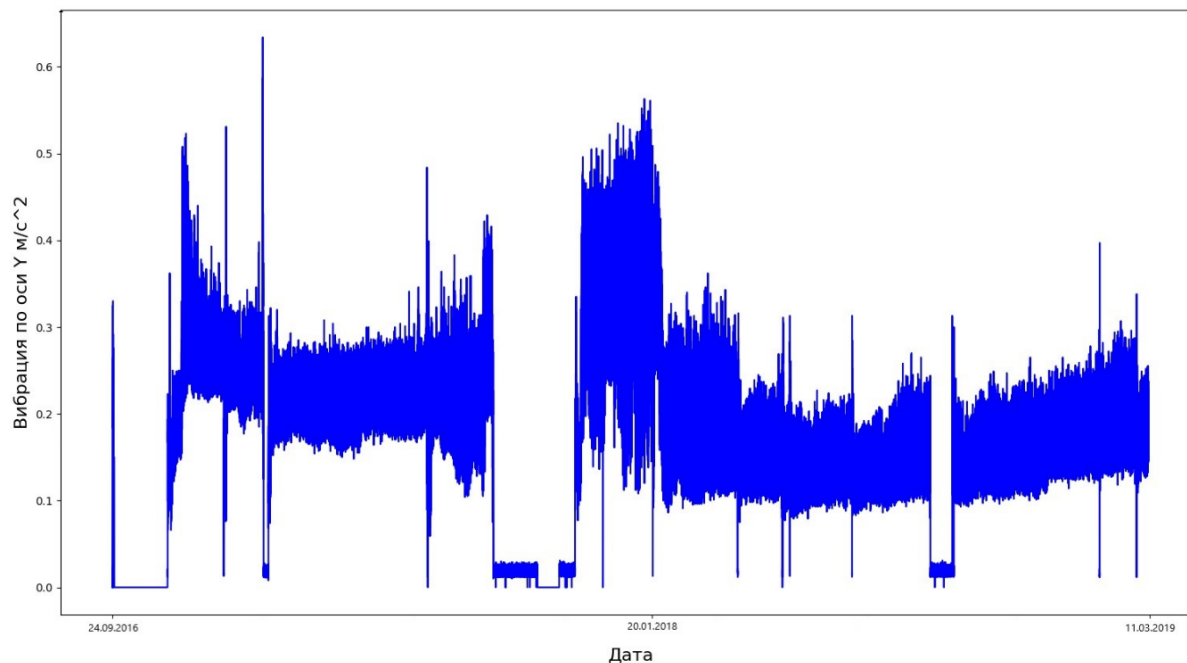


Рис. 1. График вибрации насоса по оси Y (по минутные данные)
Fig. 1. Y-axis pump vibration graph (minute data)

Анализируя исходные данные, можно сделать вывод, что насос выключали на месяц в 2016 г., на полтора месяца в 2017 г. и на неделю в конце 2018 г. Факт выключения также подтверждают данные, отображающие напряжение сети с аналогичных участков времени. Можно заметить, что после включения ЭЦН имеет другой режим работы, что обусловлено пиками в значениях вибрации, сразу после моментов выключения.

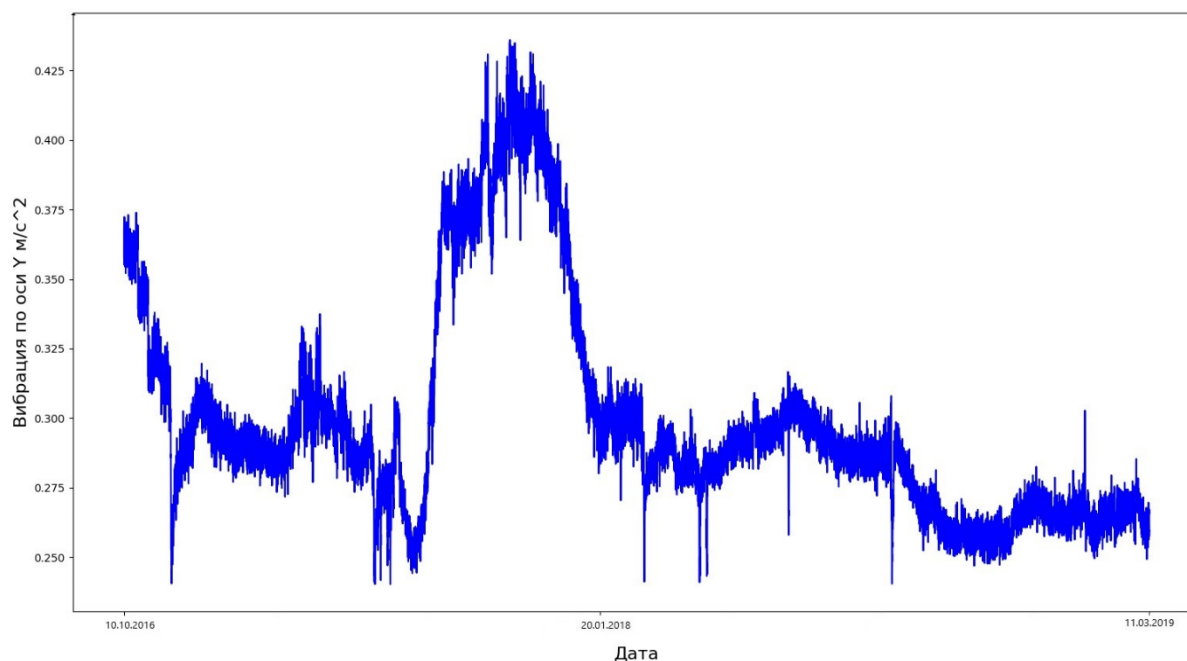


Рис. 2. Обработанный временной ряд данных вибрации насоса по оси Y (почасовые данные)
Fig. 2. Processed time series of pump vibration data in Y-axis (hourly data)

В процессе исследования исходных данных было принято решение убрать из обучающей выборки места, где фазное напряжение равнялось нулю, и очистить выборку от пиков, которые явно выбиваются из нормального режима работы. Одним из преобразований данных было уменьшение

размерности выборки за счет усреднения значений по часам. При получении значений, которые описывали работу насоса за следующие сутки, требовалось предсказать 1440 значений, а при усреднении данных по часам требовалось найти 24 значения. Уменьшение количества предсказанных значений позволит уменьшить ошибку на длительные промежутки времени. Результаты преобразований представлены на рис. 2.

Нейросетевое моделирование

По оценке автора работы [9] наиболее популярными и широко используемыми являются классы авторегрессионных и нейросетевых моделей прогнозирования. Авторегрессионные методы наподобие ARIMA [10] и его модификаций требуют определения множества подгоночных параметров, процедура определения которых не является однозначной. Кроме того, данные методы не обладают нужной степенью гибкости.

Наиболее гибкими к характеру временных рядов являются модели, основанные на ИНС. Среди моделей данного типа в приложениях к задачам прогноза выделяют глубокие сети LSTM. В работах [11–14] показана эффективность сети LSTM в задаче прогнозирования добычи нефти по сравнению с традиционными методами. LSTM оказалась точнее модели ARIMA на 8–37 % на разных месторождениях в Китае и Индии. По сравнению с модификацией метода анализа кривой спада (DCA), широко используемого в нефтяной промышленности, LSTM оказалась точнее на 17–29 %.

Поэтому в настоящей работе в качестве основного метода прогнозирования состояния ЭЦН был выбран метод нейросетевого моделирования. Причем в качестве искусственной нейронной сети (ИНС) была выбрана сеть LSTM. Данная сеть – современная рекуррентная ИНС, способная обучаться долговременным зависимостям и длительное время сохранять контекст исторических данных [15,16].

Были проведены исследования возможности прогнозирования нейросетей LSTM на короткий период времени (до 3 сут). Для обучения нейросети использовались данные вибрации насоса по оси Y в период с 24.09.2016 по 11.03.2019. Размер обучающего множества равнялся 18 425 элементам. Точность нейросетевой модели оценивалась при помощи показателя «Средняя абсолютная ошибка в процентах», формула для вычисления которого имеет вид

$$MAPE = \frac{1}{N} \sum_{t=1}^N \frac{|Z(t) - \hat{Z}(t)|}{Z(t)} \cdot 100 \%,$$

где N – количество отсчетов ряда; t – дискретное время; $Z(t)$ – значения исходного ряда; $\hat{Z}(t)$ – предсказанные значения.

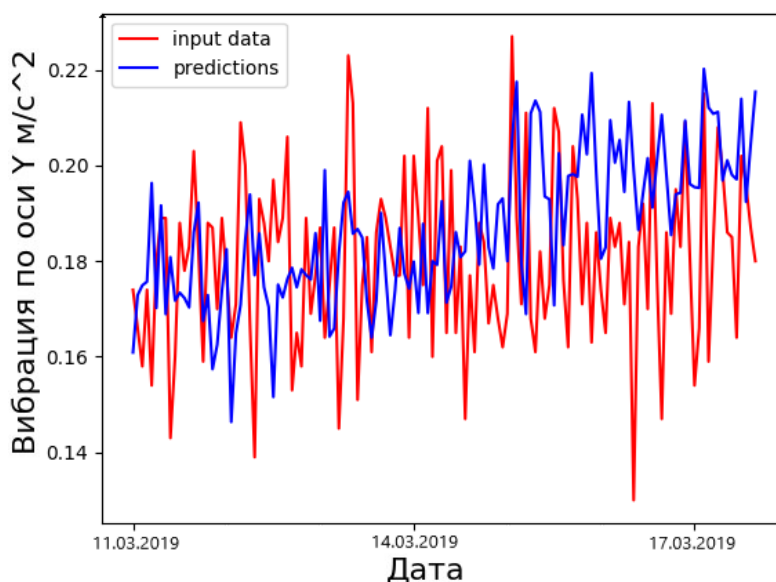


Рис. 3. Прогнозирование временного ряда на следующие 135 значений
Fig. 3. Forecasting a time series for the next 135 values

На рис. 3 приведен предсказанный временной ряд из значений вибрации насоса примерно на 5 сут (с 11.03.2019 по 17.03.2019). Для предсказания использовались 12 значений из исходных

данных в виде временного окна, которое сдвигалось на каждом шаге на одно значение, при этом каждый раз добавлялось значение, предсказанное нейронной сетью. Прогнозировались следующие 135 почасовых значений вибрации насоса. Процент средней ошибки обученной сети на всем исследованном интервале времени (MAPE) составил 11,23 %. На рис. 3 обозначены: input data – реальные данные о вибрации, полученные с датчика, а predictions – данные, предсказанные сетью. Видно, что с ростом интервала предсказания ошибка растет и в конце интервала достигает 30 %.

Для повышения точности прогноза было увеличено количества эпох в полтора раза и количество итераций в одной эпохе при обучении нейросети, таким образом количество эпох составило 1500, а количество итераций в каждой эпохе – 500. Для обучения также использовалось скользящее окно в 12 значений, выход у сети равнялся одному значению. Для предсказания использовались 12 значений из исходных данных, временное окно сдвигалось на каждом шаге на одно значение, при этом каждый раз добавлялось значение, полученное нейронной сетью. Прогнозировались следующие 135 значений. Процент средней ошибки при тестировании (MAPE) составил 10,34 %. На рис. 4 обозначения: input data – исходные данные, predictions – данные, предсказанные сетью.

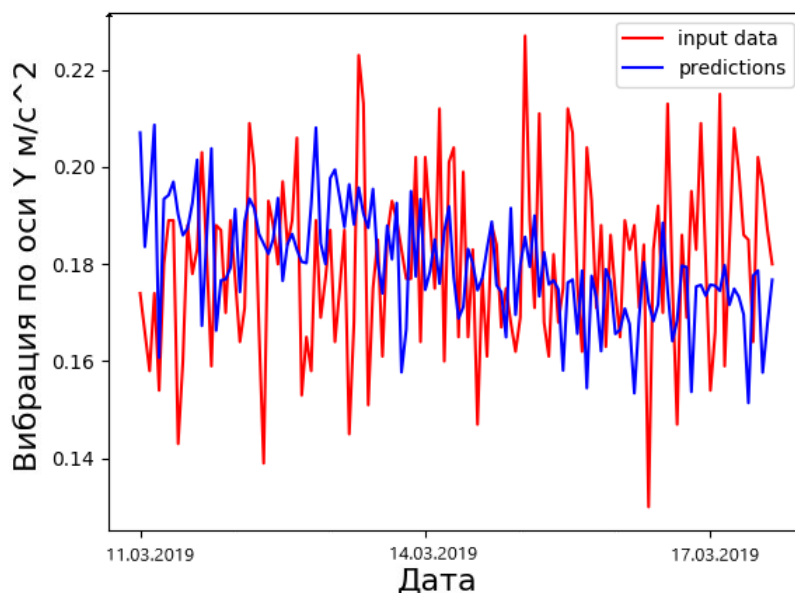


Рис. 4. Прогнозирование временного ряда на следующие 135 значений
Fig. 4. Forecasting a time series for the next 135 values

Из рис. 4 видно, что на всем интервале прогноза точность повысилась, но максимальные отклонения результатов могли достигать 20 %, что вряд ли допустимо при прогнозировании поломок в реальном времени.

Поэтому были проведены дополнительные исследования по обучению нейросетей и повышению точности прогноза. Для этого была изменена архитектура нейросети и уменьшен период прогноза до 3 сут. Рассматривались 2 варианта обучения. Обучение в обоих случаях производилось на видеокарте nvidia gtx 1080 ti, процессор Intel Core i7, оперативной памяти 16gb. Для первого варианта обучение заняло 4 ч (12 с на одну эпоху). Для второго варианта время обучения составило 11 ч (26 с на эпоху).

При первом варианте обучение осуществлялось на 1100 эпохах, а количество итераций в одной эпохе – 200. Получили следующую функцию обратного распространения ошибки (рис. 5), где по оси абсцисс показан номер эпохи, а по оси ординат – значение функции ошибки. Для обучения также использовалось скользящее окно в 12 значений, выход у сети равнялся одному почасовому значению вибрации насоса. На рис. 5 синим цветом показан график ошибки при обучении, а красным – при валидации.

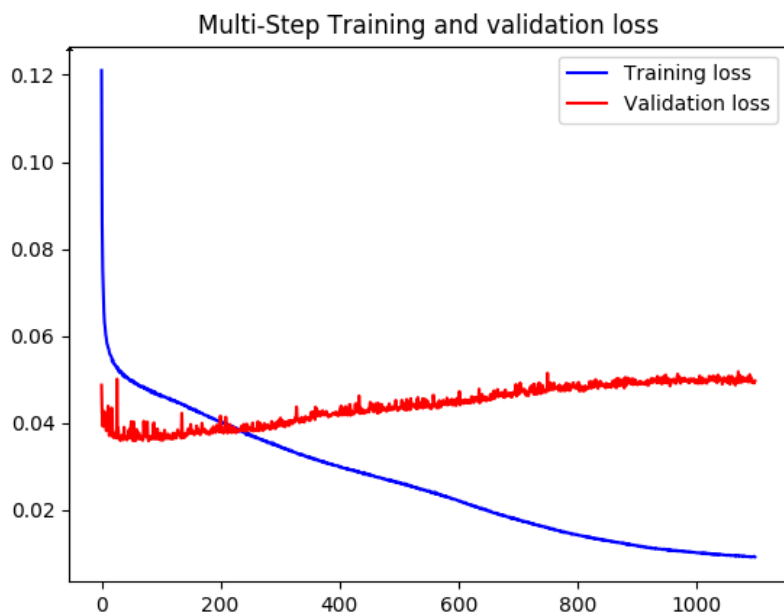


Рис. 5. Функция обратного распространения ошибки
Fig. 5. Backpropagation function

На рис. 6 представлен предсказанный временной ряд. Процент средней ошибки на всем временном интервале (MAPE) составил 2,79 %. На рис. 6 приняты следующие обозначения: input data – исходные данные, predictions – данные, предсказанные сетью. На рис. 6 также показаны предсказанные тренды (линейный – сиреневый цвет и нелинейный – зеленый цвет).

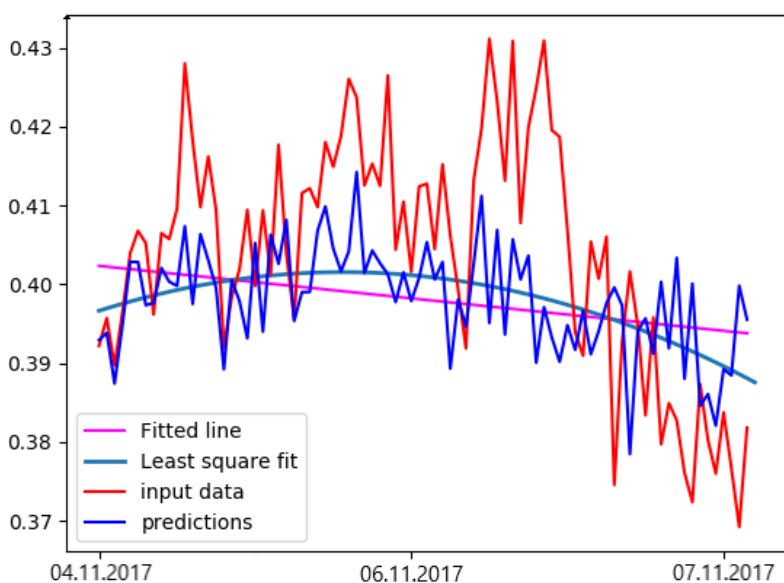


Рис. 6. Прогнозирование временного ряда на следующие 84 значения
Fig. 6. Forecasting the time series for the next 84 values

Из рис. 6 видно, что нелинейный тренд предсказан достаточно точно, но предсказанные значения вибрации в некоторых точках сильно отличаются от реальных.

Поэтому был рассмотрен второй вариант обучения с увеличенным числом итераций до 500 на каждой эпохе, количество которых также было увеличено до 1500.

Обученная нейросеть показывает неплохие результаты прогноза, приведенные на рис. 7. Процент средней по всему временному интервалу ошибки (Test MAPE) составил всего 2,54 %. На рис. 7: input data – исходные данные, predictions – данные, полученные сетью. Также на рис. 7 приведены графики линейного и нелинейного трендов.

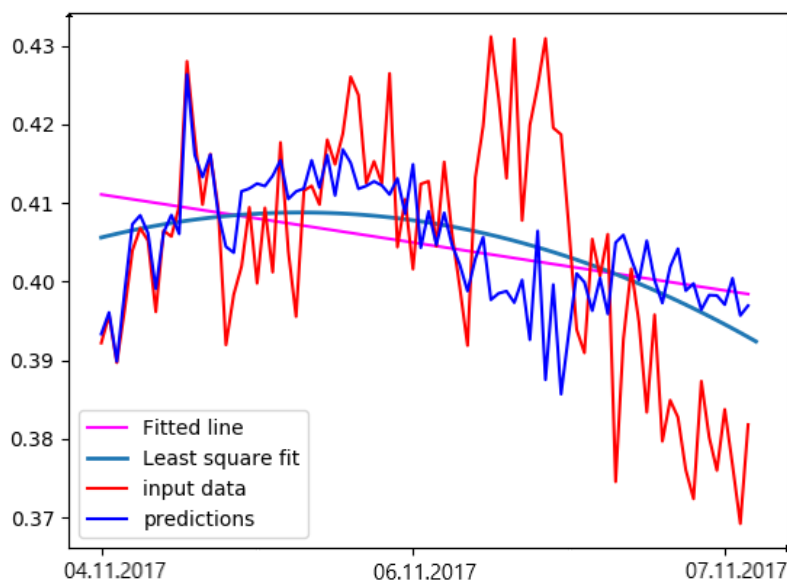


Рис. 7. Прогнозирование временного ряда на 3 суток
 Fig. 7. Forecasting the time series for 3 days

Из рис. 8 видно, обученная нейросеть практически точно предсказывает значения вибрации в первые 12 ч времени (среднее отклонение прогнозного значения от реального составляет менее 0,5 %), что является очень хорошим результатом для нейросети.

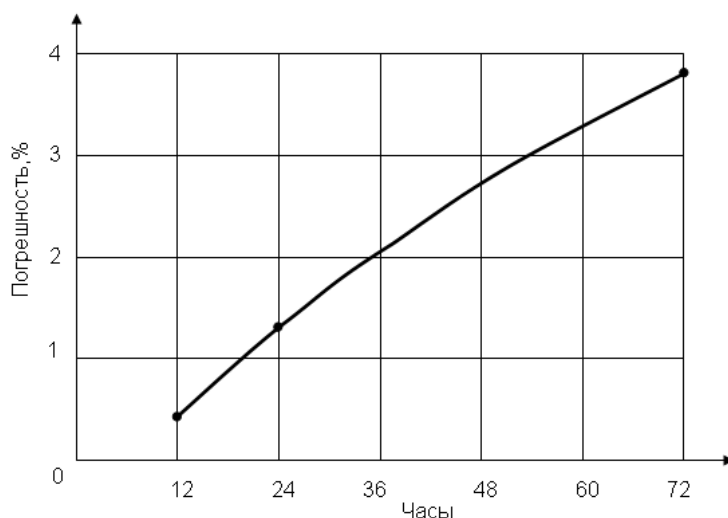


Рис. 8. Изменение средней ошибки на временном интервале прогноза
 Fig. 8. Change in the average error over the forecast time interval

Дальше погрешность растет и достигает 4 % в конце интервала прогноза, что видно из рис. 8. Данный результат можно считать приемлемым по точности прогноза на первые сутки, но обучающие сети требуют больших затрат времени.

Заключение

В результате проведенных исследований был опробован метод прогнозирования вибрации электроцентробежного насоса при помощи искусственных нейронных сетей. Анализ результатов показал, что процент ошибки довольно высок для точного прогнозирования значений, но при этом нейросети хорошо улавливают тренд внутри временного ряда, что говорит о возможности применения нейросетей совместно с экспертной системой, основанной на знаниях экспертов, представленных в виде набора правил. Определение тренда позволит экспертной системе более точно спрогнозировать поведение оборудования и за счет этого уменьшить затраты на его обслуживание.

Литература

1. Camilleri, L.A.P. How 24/7 Real-Time Surveillance Increases ESP Run Life and Uptime / L.A.P. Camilleri, J. Macdonald // *Society of Petroleum Engineers*. – 2010, January 1. DOI: 10.2118/134702-MS
2. Истомин, Д.А. Экспертная система оценки технического состояния узлов электроцентробежных насосов на основе продукционного представления знаний и нечеткой логики / Д.А. Истомин, В.Ю. Столбов, Д.Н. Платон // *Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника»*. – 2020. – Т. 20, № 1. – С. 133–143. DOI: 10.14529/ctcr200113
3. Application of a Fuzzy Expert System to Analyze and Anticipate ESP Failure Modes / D. Grasian, M. Bahatem, T. Scott, D. Olsen // *Society of Petroleum Engineers*. – 2017, November 13. DOI: 10.2118/188305-MS
4. Orchard, B. FuzzyCLIPS Version 6.10 d User's Guide / B. Orchard. – National Research Council of Canada, 2004. – 82 p.
5. Riley, Gary. CLIPS: A Tool for Building Expert Systems [online] / Gary Riley. – GHG Corporation, 2001. – <http://www.ghg.net/clips/CLIPS.html> (дата обращения: 19.04.2001).
6. Yan, Yu. Hands-On Data Science with Anaconda: Utilize the right mix of tools to create high-performance data science applications / Yu. Yan, J. Yan. – Packt Publishing-ebooks Account, 2018. – 364 p.
7. Брускин, С.Н. Модели и инструменты предиктивной аналитики для цифровой корпорации / С.Н. Брускин // *Вестник РЭУ им. Г.В. Плеханова*. – 2017. – № 5. – С. 136–139.
8. Умная платформа / А. Скобеев, Д. Маганов, В. Рогод и др. – 2019. – <https://hbr-russia.ru/innovatsii/tekhnologii/803089> (дата обращения: 11.06.2020).
9. Чучуева, И.А. Модель прогнозирования временных рядов по выборке максимального подбора: дис. ... канд. техн. наук / И.А. Чучуева. – М.: Московский государственный технический университет им. Н.Э. Баумана, 2012.
10. Spatial Bayesian Network for predicting sea level rise induced coastal erosion in a small Pacific Island / O. Sahin, R.A. Stewart, G. Faivre et al. // *Journal of Environmental Management*. – May 15 2019. – Vol. 238. – P. 341–351. DOI: 10.1016/j.jenvman.2019.03.008
11. Bretherton, F.P. A technique for objective analysis and design of oceanographic experiments applied to MODE-73 / F.P. Bretherton, R.E. Davis, C. Fandry // *Deep Sea Research and Oceanographic Abstracts*. – Elsevier, 1976. – Vol. 23, no. 7. – P. 559–582.
12. Tealab, A. Time series forecasting using artificial neural networks methodologies: A systematic review / A. Tealab // *Future Computing and Informatics Journal*. – 2018. – Vol. 3, no. 2. – p. 334–340.
13. George, E.P. Box and Gwilym M. Jenkins Time series analysis forecasting and control / E.P. George. – San Francisco: Holden-Day, 1970. – 553 p.
14. Sagheer, A. Time series forecasting of petroleum production using deep LSTM recurrent networks / A. Sagheer, M. Kotb // *Neurocomputing*. – 2019. – Vol. 323. – P. 203–213.
15. Ясницкий, Л.Н. Интеллектуальные системы / Л.Н. Ясницкий. – М.: Лаборатория знаний, 2016. – 221 с.
16. Hochreiter, S. Long short-term memory / S. Hochreiter, J. Schmidhuber // *Neural Computation: journal*. – 1997. – Vol. 9, no. 8. – P. 1735–1780.

Каракулов Игорь Владимирович, аспирант кафедры вычислительной математики, механики и биомеханики, Пермский национальный исследовательский политехнический университет, г. Пермь; karakuloviv@yandex.ru.

Клюев Андрей Владимирович, канд. физ.-мат. наук, доцент кафедры вычислительной математики, механики и биомеханики; Пермский национальный исследовательский политехнический университет, г. Пермь; kav@gelicon.biz.

Столбов Валерий Юрьевич, д-р техн. наук, профессор, заведующий кафедрой вычислительной математики, механики и биомеханики; Пермский национальный исследовательский политехнический университет, г. Пермь; valeriy.stolbov@gmail.com.

Поступила в редакцию 25 сентября 2020 г.

PREDICTING THE TECHNICAL CONDITION OF AN ELECTRIC SUBMERSIBLE PUMP BASED ON NEURAL NETWORK MODELING

I.V. Karakulov, karakuloviv@yandex.ru,

A.V. Kluiev, kav@gelicon.biz,

V.Yu. Stolbov, valeriy.stolbov@gmail.com

Perm National Research Polytechnic University, Perm, Russian Federation

Introduction. The problem of predicting the state of an Electric Submersible Pump during operation is considered. Downtime and shortages caused by pump failure lead to losses in oil production and require time to replace equipment. By predicting the condition of the equipment, it is possible to minimize pump maintenance costs and reduce well downtime. Expert systems and predictive analytics methods are used to analyze the state of systems. The scientific work uses methods that are based on artificial neural networks. **Purpose of research.** Elaboration of the issues of forecasting the technical condition of the pump through by using machine-learning models. **Materials and methods.** Equipment failure forecasting is carried out using time series analysis. The data was obtained from telemetric sensors of the monitoring system installed on an electric submersible pump. The initial data were taken at one-minute intervals. Initial data preprocessing was carried out. The data was cleared of values (peaks) that are clearly got out of normal operation and places where the phase voltage was equal to zero were removed. An artificial neural network with the LSTM neuron type is used to predict time series. Time series forecasting was carried out for five days. Evaluating system parameters over long periods allows you to assess the condition of its components and prevent equipment failure. **Results.** The possibilities of neural networks trained on the basis of data from telemetric sensors of the monitoring system for predicting the values of vertical vibration of the pump are investigated. The use of a neural network model in the form of LSTM, which has shown good results in the analysis of time series, is justified. It was found that neural networks capture the trend well within the time series, which indicates the possibility of using it together with the expert system. **Conclusion.** The proposed methods and models are tested on real data, which confirms the possibility of their use in the development of an intelligent information system for managing the technical condition of an Electric Submersible Pump during operation.

Keywords: Electric Submersible Pump, forecasting, time series, artificial neural network, estimation of forecasting accuracy, LSTM network.

References

1. Camilleri L.A.P., Macdonald J. How 24/7 Real-Time Surveillance Increases ESP Run Life and Uptime. *Society of Petroleum Engineers*, 2010, January 1. DOI: 10.2118/134702-MS
2. Istomin D.A., Stolbov V.Yu., Platon D.N. Expert System for Assessment of Technical Condition of Electric Centrifugal Pump Assemblies Based on Productive Presentation of Knowledge and Fuzzy Logic. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*, 2020, vol. 20, no. 1, pp. 133–143. (in Russ.) DOI: 10.14529/ctcr200113
3. Grassian D., Bahatem M., Scott T., Olsen D. Application of a Fuzzy Expert System to Analyze and Anticipate ESP Failure Modes. *Society of Petroleum Engineers*, 2017, November 13. DOI: 10.2118/188305-MS
4. Orchard B. *FuzzyCLIPS Version 6.10 d User's Guide*. National Research Council of Canada, 2004. 82 p.
5. Riley G. CLIPS: A Tool for Building Expert Systems [online]. GHG Corporation, 2001. Available at: <http://www.ghg.net/clips/CLIPS.html> (accessed 19 April 2001).
6. Yan Yu., Yan J. *Hands-On Data Science with Anaconda: Utilize the Right Mix of Tools to Create High-Performance Data Science Applications*. Packt Publishing-ebooks Account, 2018. 364 p.
7. Bruskin S.N. Models and Tools of Predicting Analytical Research for Digital Corporation. *Vestnik of the Plekhanov Russian University of Economics*, 2017, no. 5, pp. 135–139. (in Russ.)

8. Skobeev A., Maganov D., Roodny V. *Umnaya platforma*. [Smart platform]. Available at: <https://hbr-russia.ru/innovatsii/tekhnologii/803089> (accessed 11.06.2020).

9. Chuchueva I.A. *Model' prognozirovaniia vremennykh riadov po vyborke maksimal'nogo podobii*. *Dis. kand. tekhn. nauk* [Time series prediction model for maximum similarity sample. Cand. Sci. Diss.]. Moscow, 2012. 155 p.

10. Sahin O., Stewart R.A., Faivre G., Ware D., Tomlinson R., Mackey B. Spatial Bayesian Network for Predicting Sea Level Rise Induced Coastal Erosion in a Small Pacific Island. *Journal of Environmental Management*, 2019, vol. 238, pp. 341–351. DOI: 10.1016/j.jenvman.2019.03.008

11. Bretherton F.P., Davis R.E., Fandry C. A Technique for Objective Analysis and Design of Oceanographic Experiments Applied to MODE-73. *Deep Sea Research and Oceanographic Abstracts*, 1976, vol. 23, no. 7, pp. 559–582.

12. Tealab A. Time Series Forecasting Using Artificial Neural Networks Methodologies: A Systematic Review. *Future Computing and Informatics Journal*, 2018, vol. 3, no. 2, pp. 334–340.

13. George E., Box P., Gwilym M. *Jenkins Time Series Analysis Forecasting and Control*. San Francisco, Holden-Day, 1970. 553 p.

14. Sagheer A., Kotb M. Time Series Forecasting of Petroleum Production Using Deep LSTM Recurrent Networks. *Neurocomputing*, 2019, vol. 323, pp. 203–213.

15. Yasnitsky L.N. *Intellektual'nyye sistemy* [Intelligent Systems]. Moscow, Laboratoriya znaniy Publ., 2016. 221 p.

16. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation: journal*, 1997, vol. 9, no. 8, pp. 1735–1780.

Received 25 September 2020

ОБРАЗЕЦ ЦИТИРОВАНИЯ

Каракулов, И.В. Прогнозирование технического состояния электроцентробежного насоса на основе нейросетевого моделирования / И.В. Каракулов, А.В. Клюев, В.Ю. Столбов // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». – 2020. – Т. 20, № 4. – С. 37–46. DOI: 10.14529/ctcr200404

FOR CITATION

Karakulov I.V., Kluiev A.V., Stolbov V.Yu. Predicting the Technical Condition of an Electric Submersible Pump Based on Neural Network Modeling. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*, 2020, vol. 20, no. 4, pp. 37–46. (in Russ.) DOI: 10.14529/ctcr200404