

DOI: 10.15593/2224-9400/2016.3.01

УДК 681.518.25

А.Н. Кузьмин

Пермский национальный исследовательский
политехнический университет, Пермь, Россия

И.А. Вялых

ООО «Инфраструктура ТК», Пермь, Россия,
Пермский национальный исследовательский
политехнический университет, Пермь, Россия

ПРОГНОЗИРОВАНИЕ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ШТАНГОВЫХ ГЛУБИННЫХ НАСОСОВ НА ОСНОВЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

Одним из методов механизированной добычи нефти является добыча с применением штанговых глубинных насосов. Это объясняется их простотой, эффективностью и надежностью. Основными преимуществами штанговых глубинных насосов являются высокий КПД, технически несложный монтаж, возможность адаптации к изменяющимся условиям добычи и т.д. К недостаткам относятся ограничение по глубине спуска, высокий износ насосных штанг, трудоемкость операций по замене глубинных насосов. Заблаговременное распознавание неисправностей и профилактический ремонт позволяют избежать крупных дефектов и связанных с ними затрат.

Одним из наиболее действенных методов оперативного контроля работы штанговых глубинных насосов является динамометрирование. Динамометрирование позволяет определять нагрузку на полированный шток и, не поднимая насоса на поверхность, выявлять различные неполадки в его работе. Во многих случаях заблаговременное распознавание неполадок и профилактический ремонт позволяют избежать крупных дефектов и связанных с ними больших затрат. В связи с этим актуальными являются исследования по разработке систем прогнозирования и внедрение их в существующие автоматизированные системы управления.

В данной работе рассматривается подход к решению задачи прогнозирования технического состояния штанговых глубинных насосов с использованием нейросетевых технологий. В качестве нейронной сети используется классическая сеть с алгоритмом обучения методом обратного распространения ошибки. В качестве входов используются значения нагрузки на полированный шток, представляющие 40 последовательных динамограмм. Выходом

нейронной сети является значение нагрузки на шток 41-й динамограммы. После обучения сети делался прогноз для следующей 42-й динамограммы. Полученный прогнозный график динамограммы сравнивается с графиком реальной динамограммы, снятой динамометром со штангового глубинного насоса.

Ключевые слова: штанговый глубинный насос, техническое состояние, контроль, динамометрирование, прогнозирование, нейронная сеть.

A.N. Kuzmin

Perm National Research Polytechnic University,
Perm, Russian Federation

I.A. Vyalykh

«Infrastructure TK» LLC, Perm, Russian Federation,
Perm National Research Polytechnic University,
Perm, Russian Federation

PREDICTION OF TECHNICAL CONDITION OF ROD PUMPS BASED ON NEURAL NETWORK TECHNOLOGY

One of the methods of mechanical oil extraction is extraction with the use of rod pumps. This is due to their simplicity, efficiency and reliability. The main advantages of SRP are high efficiency, technically simple installation and adaptability to changing conditions of production, etc. The disadvantages include a limited depth of the descent, high wear of rods, the complexity of operations on replacement of deep-well pumps. Early fault detection and preventive maintenance help to avoid major defects and associated costs.

One of the most effective methods of operational control the operation of rod pumps is dynamometrical. Dynamometrical allows to determine the load on the polished rod and without lifting the pump to the surface, to identify the different problems in his work.

In many cases, early detection of problems and preventive maintenance help to avoid major defects and associated high costs.

In this regard, relevant are studies on the development of forecasting systems and their introduction into existing automated control systems.

In this paper solves the problem of forecasting the technical condition of rod pumps using neural network technology. As the neural network used classic network with the learning algorithm by the method of back propagation of error. As inputs were used the load values on the polished rod, taken from 40 of the dynamometer. The output of the neu-

ral network is the value of the load on the rod 41st dynamogram. After training the network was done the forecast for the 42nd dynamogram. The obtained predictive schedule dynamogram were compared to the schedule of real dynamogram taken with a dynamometer with a rod pump.

Keywords: *rod pump, technical condition, monitoring, dynamometrical, prediction, neural network.*

При помощи динамограмм в любой фазе движения у насосов можно определить статические и динамические нагрузки. Благодаря этому имеется постоянная информация о характере притока, работы клапанов, повреждениях клапанов, износе плунжера и цилиндра, негерметичности насосно-компрессорных труб и об объемах добычи. Интерпретацию динамограмм можно использовать для правильного расчета привода противовесов, оптимальной настройке сальника и длины хода, для диагностики обрывов штанг, выявления запарафинирования насосно-компрессорных труб или выход насоса из зоны нефти. Таким образом, удастся значительно увеличить эффективность работы насосной системы [1].

Прогнозирование – это ключевой момент при принятии решений в управлении. Конечная эффективность любого решения зависит от последовательности событий, возникающих уже после принятия решения. Возможность предсказать неуправляемые аспекты этих событий перед принятием решения позволяет сделать наилучший выбор, который, в противном случае, мог бы быть не таким удачным [2, 3].

На основании вышеизложенного можно сказать, что прогнозирование – это предсказание будущих событий. Целью прогнозирования является уменьшение риска при принятии решений.

Для задач прогнозирования широко применяется метод прогнозирования на основе нейронных сетей. Для нейронной сети выбирается:

- 1) модель нейронной сети,
- 2) количество слоев сети,
- 3) количество нейронов в каждом слое,
- 4) алгоритм обучения [4].

В данной работе была поставлена задача спрогнозировать состояние штангового глубинного насоса на глубину прогнозирования, равную одной динамограмме, и оценить достоверность полученного прогноза.

В состав системы входит классическая полносвязная нейронная сеть с алгоритмом обучения методом обратного распространения ошибки.

Динамограммы со скважины снимаются с помощью гидропривода штангового глубинного насоса «Гейзер», поступают в СУБД Microsoft SQL Server и хранятся в виде таблиц, представляющих собой функциональную зависимость нагрузки на шток (y) от хода поршня (x). Пример снятой динамограммы представлен на рис. 1.




Рис. 1. Динамограмма зависимости нагрузки на шток от хода штока

Система прогнозирования реализуется в пакете прикладных программ MATLAB. Данные в MATLAB загружаются из базы данных Microsoft SQL Server с помощью языка запросов SQL. Количество точек в динамограмме варьируется от 223 до 343.

Нейронная сеть строится с помощью встроенного инструмента синтеза и анализа нейронных сетей Neural Network Toolbox [5, 6]. Сеть состоит из трех слоев. Во входном слое – 80 нейронов, в промежуточном – 40 нейронов. Нейронная сеть работает по алгоритму с прямым распространением сигнала и обратным распространением ошибки.

У нейронов входного и промежуточного слоев использована тангенциальная функция активации, у нейронов выходного слоя использована линейная функция активации [7, 8]. Экспериментально выбрана структура нейронной сети, представленная на рис. 2. Сеть состоит из двух скрытых слоев и одного выходного.




Рис. 2. Структура нейронной сети

Первоначально данные в нейронную сеть подавались в необработанном виде. На вход сети были поданы значения хода штока (обозначается переменной x) и нагрузки на шток (обозначается переменной y) для каждой из 40 динамограмм. Данные представляли собой массив размером 40×343 (табл. 1).

Таблица 1

Структура массива данных 40 динамограмм

x_1	$x_{1,1}$	$x_{1,2}$	...	$x_{1,343}$
y_1	$y_{1,1}$	$y_{1,2}$	...	$y_{1,343}$
x_2	$x_{2,1}$	$x_{2,2}$	...	$x_{2,343}$
y_2	$y_{2,1}$	$y_{2,2}$	...	$y_{2,343}$
...	...	...	...	...
x_{40}	$x_{40,1}$	$x_{40,2}$	...	$x_{40,343}$
y_{40}	$y_{40,1}$	$y_{40,2}$	...	$y_{40,343}$

На выход сети подавались данные 41-й динамограммы (табл. 2).

Таблица 2

Структура массива данных 41-й динамограммы

x_{41}	$x_{41,1}$	$x_{41,2}$	...	$x_{41,343}$
y_{41}	$y_{41,1}$	$y_{41,2}$	...	$y_{41,343}$

Графики реальной динамограммы и динамограммы, полученной после обучения нейронной сети, представлены на рис. 3. Средняя ошибка обучения составила 5,1 %.




Рис. 3. Графики реальной динамограммы и обученной с помощью нейронной сети: — реальная динамограмма; - - - динамограмма, полученная с помощью обучения

После обучения на вход нейронной сети подавался массив данных со 2-й по 41-ю динамограмму и делался прогноз 42-й динамограммы. Результат спрогнозированной динамограммы получился некорректным (рис. 4).

Полученный результат свидетельствует о том, что необходимо на вход нейронной сети подавать данные, обработанные определенным образом. Для корректного прогноза в каждой динамограмме по оси абсцисс (ход штока – x) выбирается 200 точек и находятся соответствующие им значения по оси ординат (нагрузка на шток – y) методом кубической интерполяции. Кубическая сплайн-интерполяция позволяет провести кривую через набор точек таким образом, что первые и вторые производные кривой непрерывны в каждой точке. Эта кривая образуется путем создания ряда кубических полиномов, проходящих через наборы из трех смежных точек. Кубические полиномы затем состыковываются друг с другом, чтобы образовать одну кривую [9, 10].




Рис. 4. Результат спрогнозированной динамограммы:
 — — — спрогнозированная динамограмма; — реальная динамограмма

На вход нейронной сети подается массив значений нагрузки на шток размерностью 40×200 (табл. 3).

Таблица 3

Массив данных 40 динамограмм

y_1	$y_{1,1}$	$y_{1,2}$	...	$y_{1,200}$
y_2	$y_{2,1}$	$y_{2,2}$	...	$y_{2,200}$
...	...	...	...	...
y_{40}	$y_{40,1}$	$y_{40,2}$	...	$y_{40,200}$

Выходом является значение нагрузки на шток 41-й динамограммы:

y_{41}	$y_{41,1}$	$y_{41,2}$	...	$y_{41,200}$
----------	------------	------------	-----	--------------

На рис. 5 представлены график динамограммы, полученной с помощью обучения нейронной сети и график реальной динамограммы. Ошибка обучения составила 1,4 %.




Рис. 5. Графики динамограммы, полученной после обучения нейронной сети и реальной динамограммы: — реальная динамограмма; — динамограмма, полученная с помощью обучения

Для оценки работоспособности нейронной сети после обучения на тестовой выборке на вход модели подавалась динамограмма, идущая следом за обучающей выборкой. Результат прогноза последующей динамограммы и реальная динамограмма работы штангового насоса представлены на рис. 6. Суммарная ошибка прогнозирования последующей динамограммы составила 9,5 %, что говорит о работоспособности нейронной сети.

Для адаптации прогнозирующей математической модели предусмотрено переобучение нейронной сети путем добавления в обучающую выборку вновь измеренной динамограммы и исключения более старой.

Определение состояния глубинного штангового насоса по полученной динамограмме осуществляется в соответствии с алгоритмом, представленным в работе [11]. При внедрении алгоритма прогноза в систему диагностики технического состояния штанговых глубинных насосов полученная система позволяет прогнозировать изменение состояния глубинных насосов и оценивать динамику снижения работо-




Рис. 6. Графики спрогнозированной и реальной динамограмм:
— — — спрогнозированная динамограмма; — реальная динамограмма

способности оборудования, планировать ремонтные работы, что создаст положительный экономический эффект путем снижения затрат, связанных с простоем насосного оборудования по причине аварийных остановов, вызванных износом оборудования.

Список литературы

1. Ришмюллер Г., Майер Х. Добыча нефти глубинными штанговыми насосами: учеб. пособие. – Терниц: Изд-во Шеллер-Блекман-ГмбХ, 1988. – 150 с.
2. Четыркин Е.М. Статистические методы прогнозирования. – 2-е изд., перераб. и доп. – М.: Статистика, 1977. – 200 с.
3. Мартино Дж. Технологическое прогнозирование: пер. с англ. – М.: Прогресс, 1977. – 585 с.
4. Хайкин С. Нейронные сети: полный курс: пер. с англ. – 2-е изд. – М.: Вильямс, 2006. – 1104 с.
5. Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB 6. Кн. 4. Пакеты прикладных программ / под общ. ред. В.Г. Потемкина. – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.

6. Ануфриев И.Е., Смирнов А.Б., Смирнова Е.Н. MATLAB 7. – СПб.: БХВ-Петербург, 2005. – 1104 с.
7. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. – 2-е изд. – М.: Горячая линия-Телеком, 2002. – 382 с.
8. Кетков Ю.Л., Кетков А.Ю., Шульц М.М. MATLAB 7: программирование, численные методы. – СПб.: БХВ-Петербург, 2005. – 752 с.
9. Самарский А. А., Гулин А.В. Численные методы: учеб. пособие для вузов. – М.: Наука, 1989. – 432 с.
10. Калиткин Н.Н. Численные методы. – М.: Наука, 1978. – 512 с.
11. Шумихин А.Г., Александров И.В., Плехов В.Г. Автоматизация диагностики технического состояния штанговых глубинных насосов по динамограммам на основе методов прецедентов // Вестник Пермского национального исследовательского политехнического университета. Химическая технология и биотехнология. – 2012. – № 14. – С. 5–12.

References

1. Rishmyuller G., Majer H. Dobycha nefi glubinnymi shtangovymi nasosami [Extraction oil of road pump]. Ternits: Izd-vo Sheller-Blekman GmbH, 1988. 150 p.
2. Chetyrkin E.M. Statisticheskie metody prognozirovaniya [Statistical forecasting methods]. Moscow: Statistika, 1977. 200 p.
3. Martino Dzh. Tekhnologicheskoe prognozirovanie [Technology foresight]. – Moscow: Progress, 1977. 585 p.
4. Hajkin S. Nejronnye seti [Neural networks]. Moscow: Viljams, 2006. 1104 p.
5. Medvedev V.S., Potemkin V.G. Nejronnye seti. MATLAB 6. Kniga 4. Pakety prikladnykh programm [Neural networks. MATLAB 6. Book 4. Application packages]. Ed. by V.G. Potemkin. Moscow: DIALOG-MIFI, 2002. 496 p.
6. Anufriev I.E., Smirnov A.B., Smirnova E.N. MATLAB 7 [MATLAB 7]. Saint-Petersburg: BHV-Peterburg, 2005. 1104 p.
7. Kруглов V.V., Borisov V.V. Iskusstvennye nejronnye seti. Teoriya i praktika [Artificial neural networks. Theory and practice]. Moscow: Goryachaya liniya-Telekom, 2002. 382 p.
8. Ketkov Ju.L., Ketkov A.Ju., Shulc M.M. MATLAB 7: programmirovanie, chislennye metody [MATLAB 7: programming, numerical methods]. Saint-Petersburg: BHV-Peterburg, 2005. 752 p.
9. Samarskij A.A., Gulin A.V. Chislennye metody [Numerical methods]. Moscow: Nauka, 1989. 432 p.

10. Kalitkin N.N. Chislennyye metody [Numerical methods]. Moscow: Nauka, 1978. 512 p.

11. Shumikhin A.G., Aleksandrov I.V., Plekhov V.G. Avtomatizatsiya diagnostiki tekhnicheskogo sostoyaniya shtangovykh glubinnykh nasosov po dinamogrammam na osnove metodov pretsedentov [Automation of technical diagnostics condition of sucker rod pumps for dynamometer based on precedents methods]. *Vestnik Permskogo natsionalnogo issledovatel'skogo politekhnicheskogo universiteta. Khimicheskaya tekhnologiya i biotekhnologiya*, 2012, no. 14, pp. 5–12.

Получено 15.09.2016

Об авторах

Кузьмин Александр Николаевич (Пермь, Россия) – магистр кафедры автоматизации технологических процессов и производств Пермского национального исследовательского политехнического университета (614990, г. Пермь, Комсомольский пр., 29; e-mail: DeskOrganizer2008@yandex.ru).

Вялых Илья Анатольевич (Пермь, Россия) – кандидат технических наук, руководитель группы системных разработок ООО «Инфраструктура ТК» (614016, г. Пермь, ул. Глеба Успенского, 15а; e-mail: ilya.vyalyh@infra.ru), доцент кафедры автоматизации технологических процессов и производств Пермского национального исследовательского политехнического университета (614990, г. Пермь, Комсомольский пр., 29; e-mail: ilya.vyalyh@pstu.ru).

About the authors

Aleksandr N. Kuzmin (Perm, Russian Federation) – Master, Department of Automation of technological processes and production, Perm National Research Polytechnic University (29, Komsomolsky av., Perm, 614990, Russian Federation; e-mail: DeskOrganizer2008@yandex.ru).

Ilya A. Vyalykh (Perm, Russian Federation) – Head of system development group, ООО “Infrastructure LLC” (15a, Gleb Uspenskij str., Perm, 614016, Russian Federation; e-mail: Ilya.Vyalyh@infra.ru), Associate professor, Ph.D. of technical sciences, Department of Automation of technological processes and production, Perm National Research Polytechnic University (29, Komsomolsky av., Perm, 614990, Russian Federation; e-mail: ilya.vyalyh@pstu.ru).