

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
ПРАВИТЕЛЬСТВО Омской области
МИНИСТЕРСТВО ОБРАЗОВАНИЯ Омской области
Омский ГОСУДАРСТВЕННЫЙ ТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ
Омский НАУЧНЫЙ ЦЕНТР СО РАН
ИНСТИТУТ ПРОБЛЕМ ПЕРЕРАБОТКИ УГЛЕВОДОРОДОВ СО РАН
ИНСТИТУТ МАТЕМАТИКИ им. С. Л. СОБОЛЕВА СО РАН

ПРОБЛЕМЫ МАШИНОВЕДЕНИЯ

Материалы
III Международной научно-технической конференции
(23–24 апреля 2019 года, Омск, Россия)

В двух частях
Часть I

Омск
Издательство ОмГТУ
2019

УДК 621.01

ББК 34.4

П78

Научный редактор

П. Д. Балакин, д-р техн. наук, профессор,
заведующий кафедрой «Машиноведение» ОмГТУ

Редакционная коллегия:

Е. Г. Андреева, д-р техн. наук;

А. В. Бубнов, д-р техн. наук;

Е. Н. Еремин, д-р техн. наук;

Л. Г. Варено, д-р техн. наук;

А. Г. Козлов, д-р техн. наук;

В. Н. Ремесленников, д-р физ.-мат. наук;

А. И. Задорин, д-р физ.-мат. наук

Проблемы машиноведения : материалы III Междунар. науч.-техн.
П78 конф. (23–24 апр. 2019 г., Омск, Россия) : в 2 ч. / Минобрнауки России
[и др.] ; [науч. ред. П. Д. Балакин]. – Омск : Изд-во ОмГТУ, 2019.

ISBN 978-5-8149-2821-4

Ч. I : 320 с.

ISBN 978-5-8149-2822-1

Материалы конференции посвящены обобщению достижений в области машиноведения.

Издание предназначено для специалистов в области машиноведения, аспирантов и студентов.

УДК 621.01

ББК 34.4

*Мероприятие проводится при финансовой поддержке
Российского фонда фундаментальных исследований,
проект № 19-08-20107*

ISBN 978-5-8149-2822-1 (ч. I)

ISBN 978-5-8149-2821-4

© ОмГТУ, 2019

15. Анализ нынешнего положения изолированных систем энергоснабжения с высокими затратами на энерго. URL: http://www.cenef.ru/file/Discussion_paper1.pdf (дата обращения: 14.01.2019).

16. МРР-3.2.06.04-00. Порядок определения стоимости проектных работ для строительства в г. Москве. Введ. 23.05.2000. М. 35 с.

УДК 004.89: 621.311

ПРОГНОЗИРОВАНИЕ ЭНЕРГОПОТРЕБЛЕНИЯ СЕВЕРНОГО КАЗАХСТАНА НА ОСНОВЕ ТЕХНОЛОГИИ ГЛУБОКОГО ОБУЧЕНИЯ

FORECASTING OF ELECTRIC LOADS OF NORTH KAZAKHSTAN USING DEEP LEARNING

К. Т. Кошеков¹, П. В. Беляев², Н. И. Калантаевская¹, С. И. Латыпов¹, А. А. Савостин¹

¹Северо-Казахстанский государственный университет имени М. Козыбаева,
г. Петропавловск, Казахстан

²Омский государственный технический университет, г. Омск, Россия

K. T. Koshekov¹, P. V. Belyaev², N. I. Kalantayevskaya¹, S. I. Latypov¹, A. A. Savostin¹

¹M. Kozhybayev North Kazakhstan State University, Petropavlovsk, Kazakhstan

²Omsk State Technical University, Omsk, Russia

Аннотация. Статья посвящена вопросам прогнозирования энергопотребления в г. Петропавловск, Республика Казахстан. Предлагаются варианты применения глубоких нейронных сетей для прогнозирования. Информация об электрической нагрузке на следующий день позволит сформировать баланс в перетоках электрической мощности в энергосистеме. Обучение нейронной сети производится методом Левенберга-Марквардта. В качестве базы знаний для обучения нейронной сети предлагается использование ретроспективных данных о потребляемой мощности, температуру окружающей среды, тип дня недели. Предложенная нейронная сеть позволила достичь значения средней абсолютной ошибки прогноза MAPE 1,922%.

Ключевые слова: глубокие нейронные сети, машинное обучение, обучающая выборка, прогнозирование нагрузки, MATLAB Deep Learning Toolbox.

I. ВВЕДЕНИЕ

Балансирующий рынок электрической энергии в Республике Казахстан начал работать в имитационном режиме с 2008 года. Данный режим предусматривает все особенности функционирования балансирующего рынка электроэнергии, но без процедуры взаиморасчетов купли-продажи электроэнергии. Данная мера предусмотрена для того, чтобы участники рынка отработали все вероятные ситуации с планированием закупок и точнее корректировали свои заявки.

Таким образом, с переходом Казахстана к балансирующему рынку электрической энергии особую актуальность приобретает вопрос прогнозирования электрической нагрузки крупных промышленных объектов и энергосистемы в целом. Работа балансирующего рынка купли-продажи электрической энергии строится на свободной торговле электрической энергией, причем оплачивают участники рынка только разницу между фактически потребленной мощностью и предоставленной заявкой о потреблении. Чем меньше разница между планом и фактом потребления, тем меньше расходов несет участник рынка. Таким образом, существующие правила функционирования балансирующего рынка электрической энергии стимулируют участников рынка к составлению наиболее точного прогноза потребления электрической энергии.

II. ПОСТАНОВКА ЗАДАЧИ

В настоящее время распространение получило несколько методов прогнозирования.

Для оценки точности прогноза используется средняя абсолютная ошибка в процентах (MAPE):

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_{uj} - \hat{y}_j}{y_{uj}} \right| \times 100, \quad (1)$$

где y_{uj} – фактическое потребление электрической энергии;

$\hat{y}_j$ – прогнозируемое нейронной сетью потребление электрической энергии;

N – число примеров в обучающей выборке.

Метод исследования, основанный на авторегрессионных моделях [1, 2] имеет ряд преимуществ, но основными недостатками является низкая адаптивность и линейность, что не позволяет эффективно работать с нелинейными объектами [3]. Ошибка данного типа прогноза составляет около 4%.

Прогнозирование с помощью метода нечеткой логики [4, 5] позволяет работать со сложными объектами, неполной входной информацией, но увеличение входных переменных увеличивает вычисления экспоненциально, что приводит к сложности восприятия базы данных, ошибка оценивается в 2–3%.

Метод, основанный на применении искусственных нейронных сетей [6, 7, 8], позволяет устанавливать нелинейные зависимости между будущими и фактическими значениями процессов, также они адаптивны и масштабируемы [9]. К недостаткам следует отнести неопределенность в выборе структуры сети и настройке ее параметров, отсутствие прозрачности моделирования. Средняя абсолютная ошибка для нейронных сетей составляет около 2% [10].

Гибридные модели в основном являются комбинацией технологии прогнозирования с помощью нейронных сетей в совокупности с каким-либо другим методом [11, 12, 13, 14].

Особенностью энергопотребления является сложность в установлении функциональных зависимостей между факторами, влияющими на энергопотребление и фактической нагрузкой, а также о степени влиянии каждого фактора в отдельности и их комбинаций.

Наиболее подходящим методом прогнозирования, позволяющей учесть особенности процесса энергопотребления, являются искусственные нейронные сети. Нейронные сети позволяют осуществлять глубокий анализ данных, устанавливать зависимости между не связанными явно величинами, а также показывают быстрое действие при обработке больших массивов данных. Так база данных об энергопотреблении за 2 года будет содержать порядка 16 тысяч строк и 100 тысяч переменных и процесс энергопотребления непрерывен, в связи с чем, будет происходить постоянный прирост данных и увеличение базы данных. Для корректной работы нейронной сети появляется необходимость постоянного добавления новых данных в обучающую выборку.

Научные исследования по прогнозированию рынка электрической энергии Казахстана практически не проводились. Также, пока еще существует определенный технологический разрыв между техническими разработками, программными средствами искусственного интеллекта и возможностями их практического применения. [15] В данной работе объектом исследования является энергетическая система северного региона Казахстана. Различные объекты прогнозирования имеют свою специфику, и множество факторов, влияющих на энергопотребление, характерны именно для этого объекта или региона.

Целью работы является разработка модели прогнозирования электрической нагрузки на основе технологии глубокого машинного обучения (deep learning), а также выбор архитектуры нейронной сети и режима обучения с учетом региональных особенностей Казахстана, позволяющий осуществлять более эффективное прогнозирование электрической нагрузки с абсолютной ошибкой менее 2%.

III. ТЕОРИЯ

Энергопотребление является многофакторным процессом. В данном исследовании модель энергопотребления принята как нелинейной функцией следующего вида:

$$W = f(W_1, W_2, T, N, t), \quad (2)$$

где W – энергопотребление, МВт;

W'_1 – энергопотребление за прошлые сутки, МВт;

W'_2 – энергопотребление в аналогичный день в прошлом году, МВт;

T – температура окружающего воздуха в день фактического энергопотребления, °C;

Q – тип дня недели (рабочий, выходной или праздничный);

t – час суток.

Энергопотребление имеет устойчивые систематические изменения во времени и количество потребленной энергии в аналогичную дату в прошлом году является основой для прогнозирования, трендовой составляющей прогноза. За температуру окружающей среды взята средняя температура воздуха с градацией в 3 часа в рассматриваемый день. Также, значимым параметром является тип дня недели. Для классификации дней недели вводится параметр Q :

$$Q = \begin{cases} 0, \text{рабочий день} \\ 1, \text{выходной или праздничный день} \end{cases}$$

В качестве метода исследования используется метод глубокого машинного обучения, а именно использование глубокой нейронной сети. Преимущество перед другими методами прогнозирования заключается в высокой производительности глубокой нейронной сети, эффективной работе при больших объемах данных и росте количества данных, адаптивностью к различным объектам и процессам.

Глубокая нейронная сеть является архитектурой, анализирующей входную информацию через несколько скрытых слоев глубокой сети. В этом заключается основное отличие от простых искусственных нейронных сетей. Принцип работы глубокой нейронной сети при прогнозировании заключается в подаче информации на входной слой сети, далее происходит глубокое обучение нейронной сети и выходным параметром является прогнозируемая переменная. Так глубокая нейронная сеть содержит один входной и один выходной слой и более трех скрытых слоев. Подавая информацию с входного слоя на скрытые, нейронная сеть позволяет устанавливать и использовать наиболее значимые факторы, влияющие на результат.

Таким образом, глубокая нейронная сеть позволяет обрабатывать большой объем входной информации за малое время, имеет возможности строить зависимости при неинформативной входной информации, позволяет выявлять скрытые зависимости между входными и выходными данными.

Перечисленные параметры в формуле (2), влияющие на энергопотребление, являются входными данными нейронной сети. Выходным параметром является прогнозируемое энергопотребление в определенный час суток.

Математическое описание работы нейронной сети заключается в нахождении таких весовых коэффициентов, позволяющих минимизировать ошибку рассогласования между реакцией сети и требуемым откликом для всей обучающей выборки. [16]

$$\min E = \sum_{i=1}^p E_p = \sum_{i=1}^p \sum_{j=1}^m (y_{ij} - d_{ij})^2,$$

где y_{ij} , d_{ij} – соответственно фактическая и желаемая реакции j -го нейрона выходного слоя j -го нейрона выходного слоя на i -й входной вектор;

p – число примеров в обучающей выборке;

m – число нейронов в выходном слое.

Разработанная нейронная сеть была реализована с помощью пакета расширения среды MATLAB Deep Learning Toolbox. MATLAB является программной средой для решения технических задач, к основным преимуществам которой относится открытость системы, позволяющая пользователю самостоятельно корректировать и модифицировать стандартные функции данной среды.

Обучение глубокой нейронной сети происходило с помощью алгоритма Левенберга-Марквардта. Алгоритм Левенберга-Марквардта был независимо разработан Кеннетом Левенбергом и Дональдом Марквардтом [17, 18]. Данный алгоритм можно рассматривать как линейную комбинацию метода Гаусса-Ньютона и метода градиентного спуска. Чередование этих двух методов называется стратегией демпфирования и определяет коэффициент демпфирования. Если параметр затухания большой, алгоритм Левенберга-Марквардта регулирует параметры как в методе градиентного спуска. Если параметр демпфирования мал, алгоритм Левенберга-Марквардта обновляет параметры как в методе Гаусса-Ньютона. Перечисленные методы являются алгоритмами оптимизации для основной задачи наименьших квадратов, т. е. они используют задачи наименьших квадратов для подгонки данных [19].

IV. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ

Для обучения нейронной сети были собраны данные о потребляемой нагрузке городом Петропавловском Северо-Казахстанской области Республики Казахстан в период с 01.05.2016г по 30.04.2018г. Данные представлены АО «Северо-Казахстанская Распределительная Электросетевая Компания».

Объем потребляемой мощности принят с шагом в один час, таким образом, обучающая выборка за два календарных года составляет 17746 строк. Помимо данных о потребляемой мощности в обучающий задачник добавлены данные, влияющие на потребление – это температура окружающей среды, тип дня недели. Выдержка из обучающего задачника представлена рис. 1.

	A	B	C	D	E	F
1	Дата	Время	Потребление за прошлый год	Потребление за прошлые сутки	Средняя температура	Выходные и праздники
2	01.05.2017	0	41,43	32,10	5,9	1
3	01.05.2017	1	36,97	28,56	5,9	1
4	01.05.2017	2	33,27	27,39	5,9	1
5	01.05.2017	3	32,53	26,06	3,7	1
6	01.05.2017	4	31,57	25,50	3,7	1
7	01.05.2017	5	31,09	25,30	3,7	1
8	01.05.2017	6	27,77	22,24	4,7	1
9	01.05.2017	7	27,61	22,94	4,7	1
10	01.05.2017	8	30,85	23,58	4,7	1
11	01.05.2017	9	20,28	28,05	7,0	1
12	01.05.2017	10	37,66	30,98	7,0	1

Рис. 1. Выдержка из обучающего задачника

База данных формировалась в программе Microsoft Office Excel, так среда Matlab взаимодействует с данной программой и позволяет загружать данные в формате .xlsx.

Приведенные на рис. 1 параметры являются входными данными, подаваемыми на вход нейронов первого слоя. Количество нейронов первого слоя определяется объемом обучающей выборки. Число скрытых слоев определяется опытным путем в процессе обучения и предложенной глубокой нейронной сети составило 30 слоев. Нейронная сеть, определяя весовые характеристики связей между нейронами, находит фактически потребленную нагрузку в рассматриваемый день. Фактическое потребление электрической энергии является выходным параметром сети.

Прогноз погоды является одним из ключевых факторов в прогнозировании энергопотребления. [7] Коэффициент корреляции между температурой окружающей среды и потребляемой нагрузкой в рассматриваемой обучающей выборке составляет 0,302022. На рис. 2 представлена корреляция между упомянутыми переменными за 1 месяц – июль 2018 года.




Рис. 2. Корреляция между температурой окружающей среды и потребляемой нагрузкой

Характер нагрузки отличается в различные дни недели. При сравнении нагрузки в праздничный день 1 мая 2018 года и рабочий день 15 мая 2018 года, выявлено, что потребляемая нагрузка в праздничный день меньше рабочего в среднем на 16,5%. (рис. 3). Таким образом, в обучающей выборке дни недели классифицированы по следующему признаку, является текущий день рабочим или относится к выходным и праздничным дням.




Рис. 3. Энергопотребление в различные дни недели

Все данные обучающей выборки были нормализованы до значений в пределах от 0 до 1 для того, чтобы все значения данных лежали в одном интервале и оказывали одинаковое влияние на обучение сети. Нормализация данных осуществлялась с помощью функций MATLAB (рис. 4).

```
>> %% Load data from Excel
norm = 1;
inputs = xlsread('dataset.xlsx', sprintf('B%d:F%d', 2, 17497));
targets = xlsread('dataset.xlsx', sprintf('G%d:H%d', 2, 17497));
data = [inputs, targets];
%% Normalization
if norm == 1
    for i = 1: length(data)
        max_ = max(max(data));
        min_ = min(min(data));
        for j = 1: length(data(i,:))
            data(i,j) = (data(i,j) - min_) / (max_ - min_);
        end
    end
end
%% Save as
inputs = data(:, 1: end - 1);
targets = data(:, end);
save('inputs.mat', 'inputs');
save('targets.mat', 'targets');
```

Рис. 4. Нормализация данных

Обучение нейронной сети происходило в 3 этапа. Для этого обучающая выборка разбивается на 3 сегмента, обучающая, контрольная и тестовая, позволяя обучить нейронную сеть и проверить ее работоспособность. Экспериментальным путем установлено, что наилучший результат достигается при следующем процентном соотношении: обучающий сегмент – 50%, контрольный сегмент – 25% и тестовый – 25%.

V. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Разработанная глубокая нейронная сеть была обучена и апробирована в условиях АО «Северо-Казахстанская Распределительная Электросетевая Компания». В результате был получен комплекс характеристик, анализ которых позволил заключить следующее: при использовании предложенной глубокой нейронной сети для краткосрочного прогнозирования на одни сутки вперед значение средней абсолютной ошибки прогноза MAPE –1,922%. При прогнозировании на неделю вперед, значение средней абсолютной ошибки прогноза MAPE составляет 2,3%. Расчет значения средней абсолютной ошибки прогноза MAPE производился по формуле (1).

Краткосрочный прогноз является более эффективным и рекомендуется для прогнозирования электрической нагрузки при использовании предложенной глубокой нейронной сети. Прогнозирование на длительный период более недели осложняется отсутствием точного прогноза погоды и данных об энергопотреблении в ближайшие дни. Строить прогнозы на длительное время вперед возможно только по ретроспективным данным о нагрузке за прошлые годы.

Для примера, в табл. 1 приведены значения ошибки по часам в МВт и процентах для 21.06.2018г.

ТАБЛИЦА 1
ПРИМЕР ПРОГНОЗИРОВАНИЯ НАГРУЗКИ С ПОМОЩЬЮ ГЛУБОКОЙ НЕЙРОННОЙ СЕТИ
НА 21.06.2018г.

Дата	Фактическая нагрузка, МВт	Прогнозируемая нагрузка, МВт	Ошибка прогнозирования, МВт	Ошибка прогнозирования, %
21.06.2018 00:00	44,48	45,61	1,13	-2,54
21.06.2018 01:00	39,65	39,73	0,08	-0,20
21.06.2018 02:00	34,81	35,02	0,21	-0,61
21.06.2018 03:00	32,00	31,43	0,57	1,78
21.06.2018 04:00	29,95	29,42	0,52	1,75
21.06.2018 05:00	27,70	27,58	0,13	0,46
21.06.2018 06:00	26,52	26,21	0,31	1,18
21.06.2018 07:00	27,72	27,83	0,11	-0,39

Пример фактического и прогнозируемого энергопотребления для 01.07.2018г представлен на рис. 5.




Рис. 5. Прогнозируемая и реальная нагрузка на 01.07.2018г

Дополнительно установлено, что необходимо учитывать температуру окружающей среды, так как климат Казахстана предполагает динамичные изменения температуры в пределах $[0 \div 10]$ градусов за один день. Введение параметра температуры в обучающую выборку позволило улучшить результат прогнозирования на 1%.

Введение в обучающую выборку параметра Q , указывающего на принадлежность дня к выходному или рабочему, позволила уменьшить значение средней абсолютной ошибки на 0,2%.

VI. ВЫВОДЫ И ЗАКЛЮЧЕНИЕ

На основании оценки погрешности прогноза выявлено, что использование глубокой нейронной сети предложенной архитектуры, методов и способов обучения позволяет достичь значения средней абсолютной ошибки прогноза MAPE 1,922% при прогнозе потребления электрической энергии городом Петропавловском.

Предложенная глубокая нейронная сеть может быть адаптирована для прогнозирования энергопотребления другими энергоемкими объектами, такими как промышленные предприятия, региональные электрические сети. Для этого необходимо произвести внутренний анализ электропотребления, откорректировать обучающую базу данных и далее использовать описанную методологию.

Дальнейшее развитие исследования предполагает повышение точности прогноза с использованием расширенной базы данных и сочетании глубоких нейронных сетей с другими способами прогнозирования.

Расширение базы данных обучающей выборки позволит снизить ошибку прогнозирования, необходимо выявление параметров жестко коррелирующих с потреблением электрической мощности. В дальнейшем предполагается включение в обучающую выборку таких параметров как направление ветра, влажность воздуха, длина светового дня и т.д.

СПИСОК ЛИТЕРАТУРЫ

1. Cui Herui and Peng Xu. Short-Term City Electric Load Forecasting with Considering Temperature Effects: An Improved ARIMAX Model // Mathematical Problems in Engineering. 2015. Vol. Article ID 589374. p. 10. Doi.org/10.1155/2015/589374.
2. Huang S. J. and Shih K. R. Short-term load forecasting via ARMA model identification including non-Gaussian process considerations // IEEE Trans. Power Syst. 2003. Vol. 18, no. 2, P. 673–679.
3. Pradhan R. P., Kumar R. Forecasting Exchange Rate in India: An Application of Artificial Neural Network Model // Journal of Mathematics Research. 2010. Vol. 2, no. 4. P. 111–117.
4. Swati Takiyar, Upadhyay K. G. 1 & Vivek Singh2 Fuzzy ARTMAP and GARCH-based hybrid model aided with wavelet transform for shortterm electricity load forecasting // Energy Science and Engineering. 2016. No. 4(1). P. 14–22.
5. Piyali Ganguly , Akhtar Kalam, Aladin Zayegh Short term load forecasting using fuzzy logic // International Conference on Research in Education and Science (ICRES), May 18–21, 2017. Ephesus-Kusadasi/Turkey.
6. Zhisheng Zhang and Wenjie Gong. Short-Term Load Forecasting Model Based on Quantum Elman Neural Networks // Mathematical Problems in Engineering 2016. Vol. Article ID 7910971, 8 p. Doi.org/10.1155/2016/7910971.
7. Taylor J. W. and Buizza R. Neural network load forecasting with weather ensemble predictions // IEEE Trans. Power Syst. 2002. Vol. 17, no. 3. P. 626–632.
8. Osman Z. H., Awad M. L., Mahmoud T. K. Neural network based approach for short-term load forecasting // Power Systems Conference and Exposition. PSCE '09. IEEE/PES, 15–18 March 2009. Vol. 7, no. 2.8. P. 1–8.
9. Хайкин С. Нейронные сети: полный курс. М.: ООО «И. Д. Вильямс», 2006. 1104 с.
10. Mazengia D. H. Forecasting Spot Electricity Market Prices Using Time Series Models: Thesis for the degree of Master of Science in Electric Power Engineering Gothenburg, Chalmers University of Technology, 2008. 89 p.

11. Balwant singh Bisht Rajesh M Holmukhe Electricity load forecasting by artificial neuralnetwork model using weather data // International journal of electrical engineering & technology (IJEET). 2013. Vol. 4, Is. 1. P. 91–99.
12. Zheng T, Girgis A. A., Makram E. B. A hybrid wavelet-Kalman filter method for load forecasting // Electr Pow Syst Res. 2000. Vol. 54(1). P. 11–17.
13. Hongze Li, Liuyang Cui, and Sen Guo. A Hybrid Short-Term Power Load Forecasting Model Based on the Singular Spectrum Analysis and Autoregressive Model // Advances in Electrical Engineering. 2014. Vol. Article ID 424781. P. 7. Doi.org/10.1155/2014/424781.
14. A Hybrid Forecasting Model Based on Bivariate Division and a Backpropagation Artificial Neural Network Optimized by Chaos Particle Swarm Optimization // Day-Ahead Electricity Price Conference and Exposition, PSCE '09. IEEE/PES, 15–18 March 2009. P. 1–8.
15. Кошеков К. Т., Кашевкин А. А., Латыпов С. И., Савостина Г. В., Кошеков А. К. An Intelligent System for Vibrodiagnostics of Oil and Gas Equipment // Russian Journal Nondestructive Testing. 2018. Vol. 54, no. 4. P. 249–259.
16. Манов Н. А. [и др.]. Новые информационные технологии в задачах оперативного управления электро-энергетическими системами // Ин-т социально-экономических и энергетических проблем Севера. Екатеринбург : Уральское отделение РАН (УрО РАН). М.: Энергоатомиздательство, 2002. 78 с.
17. Levenberg K. A method for the solution of certain problems in least squares // Quarterly of Applied Mathematics. 1944. No. 5. P. 164–168.
18. Marquardt D. An algorithm for least-squares estimation of nonlinear parameters // SIAM Journal on Applied Mathematics. 1963. Vol. 11(2). P. 431–441.
19. Protić, D. Feedforward neural networks: the Levenberg-Marquardt optimization and optimal brain surgeon pruning // Military technical courier. 2015. Vol. LXIII, no. 3. P. 11–28.

УДК 621.317.08

МОДЕРНИЗАЦИЯ АКУСТИЧЕСКОГО МЕТОДА ДИАГНОСТИКИ СИЛОВЫХ ТРАНСФОРМАТОРОВ НА ОСНОВЕ ЦИФРОВОЙ ОБРАБОТКИ СИГНАЛОВ

MODERNIZATION OF ACOUSTIC METHOD FOR THE DIAGNOSTICS OF POWER TRANSFORMERS BASED ON DIGITAL SIGNAL PROCESSING

К. Т. Кошеков¹, П. В. Беляев², С. И. Латыпов¹, А. А. Савостин¹,
Н. И. Калантаевская¹, В. Ю. Кобенко², Б. В. Кошекova¹

¹Северо-Казахстанский государственный университет имени М. Козыбаева,
г. Петропавловск, Казахстан

²Омский государственный технический университет, г. Омск, Россия

K. T. Koshekov¹, P. V. Belyaev², S. I. Latypov¹, A. A. Savostin¹,
N. I. Kalantayevskaya¹, V. Yu. Kobenko², B. V. Koshekova¹

¹M. Kozbayev North Kazakhstan State University, Petropavlovsk, Kazakhstan

²Omsk State Technical University, Omsk, Russia

Аннотация. Описана технология модернизации акустической диагностики маслonaполненных трансформаторов путем подключения дополнительного интеллектуального блока анализа временных и статистических характеристик измерительного сигнала. Алгоритм функционирования блока основан на применении технологий искусственного интеллекта, идентификационных измерений и цифровой обработки диагностических сигналов, классификации параметров по назначенным классам сигнала и выводе о состоянии объекта с наименованием. Представлены результаты исследований образов измерительных сигналов диагностики трансформаторов, эксплуатируемых на базе АО «СЕВКАЗЭНЕРГО».

Ключевые слова: акустическая диагностика, обработка измерительных сигналов, идентификационные измерения, статистические параметры

1. ВВЕДЕНИЕ

В настоящее время основными элементами электроэнергетических сетей и систем является маслonaполненные силовые трансформаторы. В процессе эксплуатации в них могут возникать развивающиеся дефекты, связанные с неполной или высокой влажностью пропитки изоляции, пробоем твердой изоляции, износом соедине-

СЕКЦИЯ 2. ЭЛЕКТРОМЕХАНИЧЕСКОЕ, ТЕПЛОЭНЕРГЕТИЧЕСКОЕ ОБОРУДОВАНИЕ И ТЕХНОЛОГИИ

П. В. Беляев, А. П. Головский

КОНТРОЛЬ И ОСМОТР ВЫСОКОВОЛЬТНЫХ ЛИНИЙ ЭЛЕКТРОПЕРЕДАЧ С ПРИМЕНЕНИЕМ БЕСПИЛОТНЫХ ЛЕТАТЕЛЬНЫХ АППАРАТОВ В УСЛОВИЯХ КРАЙНЕГО СЕВЕРА.....	234
---	-----

А. А. Бубенчиков, И. С. Лебедев, Т. В. Бубенчикова, Н. А. Терещенко

ЭКОНОМИЧЕСКОЕ ОБОСНОВАНИЕ ИСПОЛЬЗОВАНИЯ АВТОНОМНЫХ ИСТОЧНИКОВ ЭНЕРГОСНАБЖЕНИЯ ДЛЯ СТРОИТЕЛЬНЫХ И ХОЗЯЙСТВЕННЫХ НУЖД В УСЛОВИЯХ РЕЗКО КОНТИНЕНТАЛЬНОГО КЛИМАТА	238
---	-----

К. Т. Кошеков, П. В. Беляев, Н. И. Калантаевская, С. И. Латыпов, А. А. Савостин

ПРОГНОЗИРОВАНИЕ ЭНЕРГОПОТРЕБЛЕНИЯ СЕВЕРНОГО КАЗАХСТАНА НА ОСНОВЕ ТЕХНОЛОГИИ ГЛУБОКОГО ОБУЧЕНИЯ.....	246
--	-----

*К. Т. Кошеков, П. В. Беляев, С. И. Латыпов, А. А. Савостин, Н. И. Калантаевская,
В. Ю. Кобенко, Б. В. Кошекoва*

МОДЕРНИЗАЦИЯ АКУСТИЧЕСКОГО МЕТОДА ДИАГНОСТИКИ СИЛОВЫХ ТРАНСФОРМАТОРОВ НА ОСНОВЕ ЦИФРОВОЙ ОБРАБОТКИ СИГНАЛОВ.....	252
---	-----

А. А. Кузнецов, М. А. Кузнецова

ОПРЕДЕЛЕНИЕ ПОРОГОВЫХ ЗНАЧЕНИЙ ПРИ ДИАГНОСТИРОВАНИИ ИЗОЛЯЦИИ ВЫСОКОВОЛЬТНОГО ОБОРУДОВАНИЯ АКУСТИЧЕСКИМИ МЕТОДАМИ.....	258
--	-----

Л. В. Мостовенко, В. П. Белоглазов

ЧИСЛЕННОЕ МОДЕЛИРОВАНИЕ ДВИЖЕНИЯ ЗАПЫЛЕННОГО ПОТОКА В ИВЗ	264
---	-----

В. Ф. Мухин, Е. Н. Еремин

СОВЕРШЕНСТВОВАНИЕ ОДНОФАЗНОГО ВЫПРЯМИТЕЛЯ ДЛЯ РУЧНОЙ ДУГОВОЙ СВАРКИ ШТУЧНЫМ ЭЛЕКТРОДОМ ТОНКОЛИСТОВЫХ КОНСТРУКЦИЙ.....	270
---	-----

А. М. Парамонов, Е. М. Резанов

ОПРЕДЕЛЕНИЕ ЦЕЛЕСООБРАЗНОЙ СТЕПЕНИ УТИЛИЗАЦИИ ТЕПЛОТЫ ОТХОДЯЩИХ ГАЗОВ ТЕРМОМАСЛЯНОГО ОБОРУДОВАНИЯ.....	274
---	-----

И. А. Рындин, В. Н. Брендаков, С. Н. Кладиев

ИССЛЕДОВАНИЕ ДИНАМИКИ РАЗГОНА ГОРИЗОНТАЛЬНОЙ РАЗДЕЛИТЕЛЬНОЙ ЦЕНТРИФУГИ ДЛЯ ОЧИСТКИ БУРОВЫХ РАСТВОРОВ.....	279
--	-----

В. И. Трушляков, А. А. Новиков, И. Ю. Лесняк, Е. Chillemi

ИССЛЕДОВАНИЕ ВЛИЯНИЯ ЧАСТОТЫ УЛЬТРАЗВУКОВОГО ВОЗДЕЙСТВИЯ И ПОНИЖЕННОГО ДАВЛЕНИЯ НА ПРОЦЕСС ИСПАРЕНИЯ ЖИДКОСТИ.....	286
---	-----

Научное издание

ПРОБЛЕМЫ МАШИНОВЕДЕНИЯ

Материалы
III Международной научно-технической конференции
(23–24 апреля 2019 года, Омск, Россия)

В двух частях
Часть I

Печатается в авторской редакции

Компьютерная верстка *Л. Ю. Бутаковой*

Для дизайна обложки использованы материалы
из открытых интернет-источников

Подписано в печать 22.04.19. Формат 60×84¹/₈. Отпечатано на дупликаторе.
Бумага офсетная. Усл. печ. л. 20,00. Уч.-изд. л. 20,00.
Тираж 300 экз. Заказ 221.

Издательство ОмГТУ. 644050, г. Омск, пр. Мира, 11; т. 23-02-12.
Типография ОмГТУ.