

УДК 621.316

Горбунов Игорь Николаевич, студент, Захаренко Сергей Геннадьевич, доцент, Захаров Сергей Александрович, доцент, Малахова Татьяна Федоровна, доцент,

Кузбасский государственный технический университет имени Т.Ф. Горбачева, 650000, Россия, г. Кемерово, ул. Весенняя, 28

E-mail: gorbunov24@bk.ru

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В ЦЕЛЯХ ОПРЕДЕЛЕНИЯ МЕСТА ПОВРЕЖДЕНИЯ ВОЗДУШНЫХ И КАБЕЛЬНЫХ ЛИНИЙ ЭЛЕКТРОПЕРЕДАЧИ

Аннотация: Уровень развития электросетевого комплекса – это один из важнейших показателей уровня развития не только электроэнергетики государства, но и экономики в целом. Электроэнергетическая отрасль развивается во многом благодаря инновационным, прорывным технологиям, которые ученые открывают и успешно применяют в других отраслях народного хозяйства. Чтобы идти в ногу с техническим прогрессом, электроэнергетика вынуждена адаптироваться, а также работать на опережение, учитывая курс будущего развития прорывных, инновационных технологий, подготавливая почву для их непосредственного внедрения. В данной работе будет произведена оценка возможности применения технологий больших данных, машинного обучения и нейронных сетей в целях повышения надежности системы электроснабжения территориальной сетевой организации (далее – ТСО) и будет показано, что необходимо сделать для возможности дальнейшего применения этих технологий в условиях Кемеровской области и России. Это положительно образом отразится на надежности электроснабжения потребителей.

Ключевые слова: электроэнергетическая система, определение места повреждения, искусственная нейронная сеть.

Информация о статье: принята 01 октября 2019 г.
DOI: 10.26730/1816-4528-2019-4-48-55

Наиболее перспективными технологиями для применения в целях повышения надежности систем электроснабжения являются большие данные, нейронные сети и машинное обучение. Эти технологии тесно взаимосвязаны друг с другом, поэтому при использовании их в совокупности достигается синергетический эффект. Поэтому в целях ускорения процесса восстановления нормального режима электроснабжения потребителей применен метод, основанный на сокращении времени поиска мест повреждений воздушных и кабельных линий электропередачи с использованием нейронной сети.

Большие финансовые и материальные потери, к которым приводит выход из строя ЛЭП, наталкивают на поиск наиболее эффективных и наименее дорогостоящих методов устранения таких аварий. Максимальная вероятность правильного определения места повреждения (ОМП) и минимальное время, затрачиваемое на это мероприятие, обусловлено применяемым методом и оборудованием.

Руководствуясь настоящими законодательными актами Российской Федерации, векторами развития современной электроэнергетики, а также концепцией ИЭС ААС, разработана нейронная сеть, определяющая место повреждения воздушных и кабельных линий электропередачи.

В отношении воздушных ЛЭП целесообразность разработки обусловлена тем, что существующие методы определения мест повреждения – импедансный и волновой – имеют существенный общий недостаток. Он заключается в том, что эти методы имеют погрешность расчетов в пределах до 20%, которая повторяется каждый раз, и приборы, основанные на этих методах, имеют относительно высокую стоимость. Другими словами, приборы, основанные на данных методах, не способны использовать опыт предыдущих расчетов в целях определения мест повреждения для того, чтобы в дальнейшем сократить погрешность, тем самым повысив точность.

Функция активации нейрона описывается сигмоидальной функцией:

$$y = \frac{1}{1 + e^{-x}} \quad (1)$$

Процесс обратного распространения ошибки описан формулой:

$$e_{\text{скрытый}} = e_{\text{выходной},1} \cdot \frac{w_{1,1}}{w_{1,1} + w_{2,1}} + e_{\text{выходной},2} \cdot \frac{w_{1,2}}{w_{1,2} + w_{2,2}} \quad (2)$$

где: e – величина ошибки;



Рис. 1. Искусственный нейрон с несколькими входами
 Fig. 1. Artificial neuron with multiple inputs

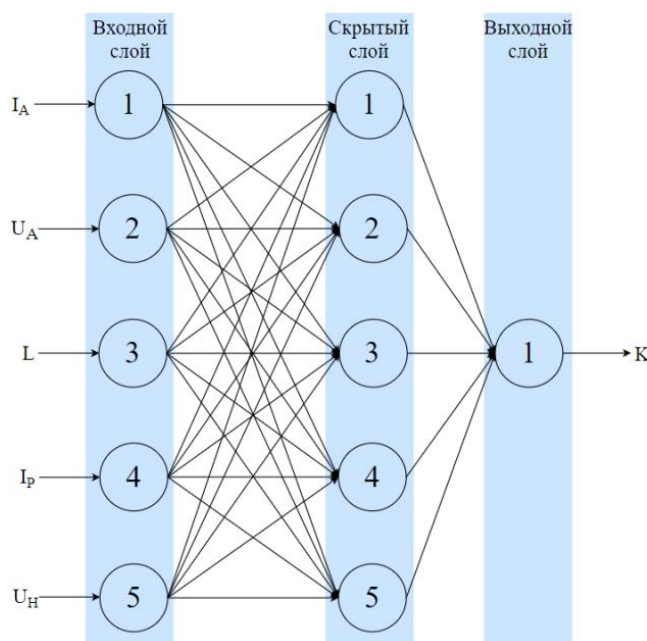


Рис. 2. Модель нейронной сети, определяющей место повреждения ЛЭП
 Fig. 2. Model of the neural network that determines the location of damage to power lines

$w_{n,m}$ – весовой коэффициент связи между нейроном j слоя и нейроном k слоя.

Дифференциальное уравнение, которое используется для изменения веса W_{jk} :

$$\frac{\partial E}{\partial W_{jk}} = -(t_k - o_k) \cdot \sigma(\sum_j W_{jk} \cdot o_j) \cdot (1 - \sigma(\sum_j W_{jk} \cdot o_j)) \cdot o_j \quad (3)$$

где: E – ошибка;

t_k – целевое значение;

o_k – фактическое значение;

o_j – выходной сигнал узла предыдущего скрытого слоя;

σ – функция активации нейрона (сигмоида).

Градиент функции ошибки по весовым коэффициентам связей между входным и скрытым слоями приобретает следующий вид:

$$\frac{\partial E}{\partial W_{ij}} = -(e_j) \cdot \sigma(\sum_i W_{ij} \cdot o_i) \cdot (1 - \sigma(\sum_i W_{ij} \cdot o_i)) \cdot o_i \quad (4)$$

Кроме этого, мы сглаживаем интересные изменения параметров посредством коэффициента обучения, который можно настраивать с учетом особенностей конкретной задачи:

$$\text{новый } W_{jk} = \text{старый } W_{jk} - \alpha \cdot \frac{\partial E}{\partial W_{jk}}, \quad (5)$$

где α – коэффициент обучения.

Коэффициент обучения сглаживает величину изменений во избежание перескоков через ложный минимум градиента.

В матричной записи вычисления будут выглядеть следующим образом:

$$\begin{pmatrix} \Delta W_{1,1} & \Delta W_{2,1} & \Delta W_{3,1} & \dots \\ \Delta W_{1,2} & \Delta W_{2,2} & \Delta W_{3,2} & \dots \\ \Delta W_{1,3} & \Delta W_{2,3} & \Delta W_{j,k} & \dots \\ \dots & \dots & \dots & \dots \end{pmatrix} = \begin{pmatrix} E_1 \cdot S_1 \cdot (1 - S_1) \\ E_2 S_2 \cdot (1 - S_2) \\ E_k S_k \cdot (1 - S_k) \\ \dots \end{pmatrix} \cdot \begin{pmatrix} O_1 & O_2 & \dots & \dots \end{pmatrix} \quad (6)$$

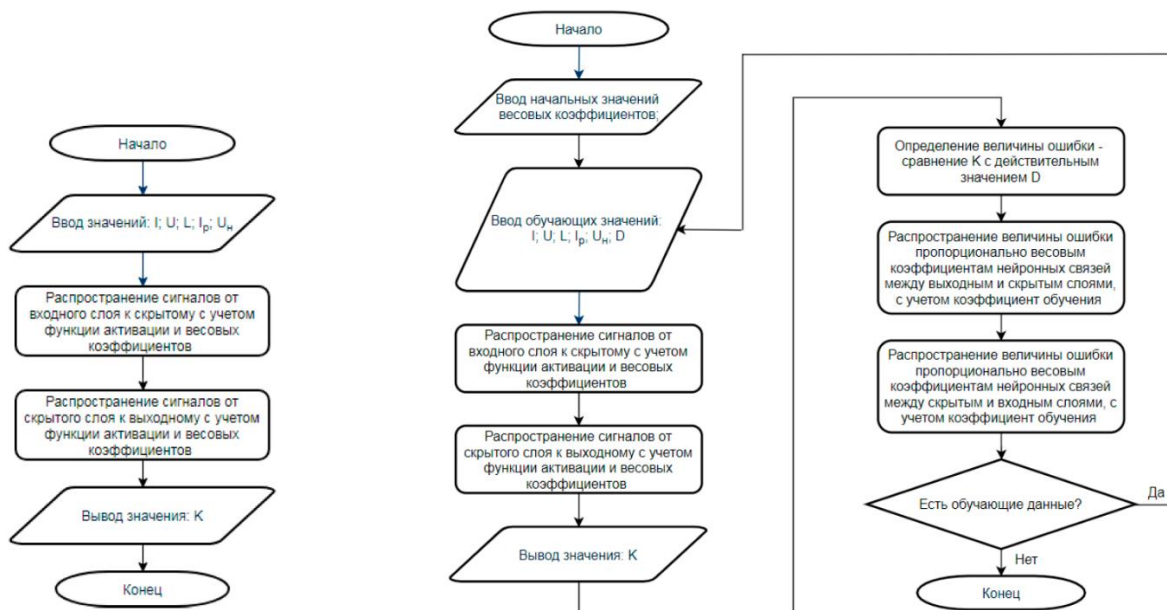


Рис. 3. Блок-схемы алгоритмов распространения входных сигналов (слева) и обучения (справа) нейронной сети

Fig. 3. Block diagrams of input signal propagation algorithms (left) and training (right) of a neural network

Коэффициент обучения в матричном умножении не фигурирует, т.к. он является константой.

Для того, чтобы реализовать проект нейронной сети, необходимо соблюсти несколько этапов: выбрать оптимальный набор входных переменных, определить веса нейронных связей, протестировать полученную модель на работоспособность.

В настоящее время оптимальный набор входных параметров для обучения нейронных сетей определяется на основе существующих знаний о процессе и о параметрах, от которого он зависит или может зависеть по оценкам экспертов.

На основании существующего опыта эксплуатации линий электропередачи и методов определения их мест повреждений были выбраны наиболее оптимальные параметры, ими являются ток, напряжение и расстояние.

Причиной, по которой был выбран путь использования именно величины расстояния от начала линии до точки повреждения ЛЭП, а не географических координат в формате «градусы, минуты, секунды», является тот факт, что линии электропередачи не являются прямыми линиями. Это в разы усложняет процесс обучения.

Более оптимальным путем является определение расстояния от начала линии до точки повреждения ЛЭП с использованием нейронной сети и дальнейшим преобразованием этого значения в географическую координату (градусы, минуты, секунды) в соответствии с топологией электрических сетей и линией, на которой применяется данная система.

В качестве набора входных переменных выбраны: сила тока при КЗ на фазе (I); напряжение при КЗ на фазе (U); длина линии (L); рабочий ток линии (I_p); номинальное напряжение линии (U_n). Конечным ответом нейронной сети, который соответствует расстоянию от начала линии до места повреждения, является переменная – K.

Правильным ответом для определения величины ошибки в ходе обучения нейронной сети является расстояние от начала линии до места повреждения (D).

Таким образом, нейронная сеть имеет 5 входных значений, 5 нейронов (узлов) на входном слое, 5 нейронов на скрытом слое, 1 узел на выходном слое и одно выходное значение, соответствующее расстоянию от начала линии до места повреждения.

Код, описывающий модель нейронной сети, которая создана определять место повреждения воздушных и кабельных линий электропередачи, написан на языке Python. Данный язык программирования широко применяется среди организаций и программистов, занимающихся разработкой и обучением нейронных сетей. Средой разработки на языке Python является бесплатный дистрибутив для научных вычислений с открытым исходным кодом Anaconda версии 3.7 и Jupyter Notebook.

Программный код класса нейронной сети полностью описан. Стоит отметить, что он является достаточно универсальным. Это достигнуто путем применения в коде различных переменных, а не конкретных значений. Поэтому код может быть использован с целью создания, тренировки и опроса трехслойной нейронной сети практически для любой задачи электроэнергетической отрасли.

Для тестирования программного кода за расчетную ЛЭП принята воздушная линия электропередачи напряжением 110 кВ, ее протяженность составляет 7 км.

Данные для нейронной сети будут представлены в виде однострочного массива: [13,28; 0; 7; 0,06; 110]. После обработки информации нейронная сеть выдает числовой ответ, равный 3,677 км. Данная информация подлежит дальнейшей обработке для визуального отображения в геоинформационной системе (далее – ГИС).

```

# определение класса нейронной сети
class neuralNetwork:
    # инициализировать нейронную сеть
    def __init__(self, inputnodes, hiddennodes, outputnodes, learningrate) :
        # задать количество узлов во входном, скрытом и выходном слое
        self.inodes = inputnodes
        self.hnodes = hiddennodes
        self.onodes = outputnodes

        # Матрицы весовых коэффициентов связей wih (между входным и скрытым слоями) и who (между скрытым и выходным).
        # Весовые коэффициенты связей между узлом i и узлом j следующего слоя обозначены как w_i_j:
        # w11 w21
        # w12 w22 и т.д.

        self.wih = numpy.random.normal(0.0, pow(self.hnodes, -0.5), (self.hnodes, self.inodes))
        self.who = numpy.random.normal(0.0, pow(self.onodes, -0.5), (self.onodes, self.hnodes))

        # коэффициент обучения
        self.lr = learningrate
        # использование сигмоиды в качестве функции активации
        self.activation_function = lambda x: scipy.special.expit(x)

    pass

# тренировка нейронной сети
def train(self, inputs_list, targets_list):
    # преобразование списка входных значений в двумерный массив
    inputs = numpy.array(inputs_list, ndmin=2).T
    targets = numpy.array(targets_list, ndmin=2).T

    # рассчитать входящие сигналы для скрытого слоя
    hidden_inputs = numpy.dot(self.wih, inputs)
    # рассчитать исходящие сигналы для скрытого слоя
    hidden_outputs = self.activation_function(hidden_inputs)

    # рассчитать входящие сигналы для выходного слоя
    final_inputs = numpy.dot(self.who, hidden_outputs)
    # рассчитать исходящие сигналы для выходного слоя
    final_outputs = self.activation_function(final_inputs)

    # ошибки выходного слоя = (целевое значение - фактическое значение)
    output_errors = targets - final_outputs
    # ошибки скрытого слоя - это ошибки output_errors, распределенные
    # пропорционально весовым коэффициентам связей и рекомбинированные на скрытых узлах
    hidden_errors = numpy.dot(self.who.T, output_errors)

    # обновить весовые коэффициенты для связей между скрытым и выходным слоями
    self.who += self.lr * numpy.dot((output_errors * final_outputs * (1.0 - final_outputs)), numpy.transpose(hidden_outputs))

    # обновить весовые коэффициенты для связей между входным и скрытым слоями
    self.wih += self.lr * numpy.dot((hidden_errors * hidden_outputs * (1.0 - hidden_outputs)), numpy.transpose(inputs))

    pass

# опрос нейронной сети
def query(self, inputs_list):
    # преобразовать список входных значений в двумерный массив
    inputs = numpy.array(inputs_list, ndmin=2).T
    # рассчитать входящие сигналы для скрытого слоя
    hidden_inputs = numpy.dot(self.wih, inputs)
    # рассчитать исходящие сигналы для скрытого слоя
    hidden_outputs = self.activation_function(hidden_inputs)
    # рассчитать входящие сигналы для выходного слоя
    final_inputs = numpy.dot(self.who, hidden_outputs)
    # рассчитать исходящие сигналы для выходного слоя
    final_outputs = self.activation_function(final_inputs)
    return final_outputs

    pass

```

Рис. 4. Скриншот Jupyter Notebook с фрагментом разработанного программного кода
 Fig. 4. Screenshot of Jupyter Notebook with a fragment of the developed program code

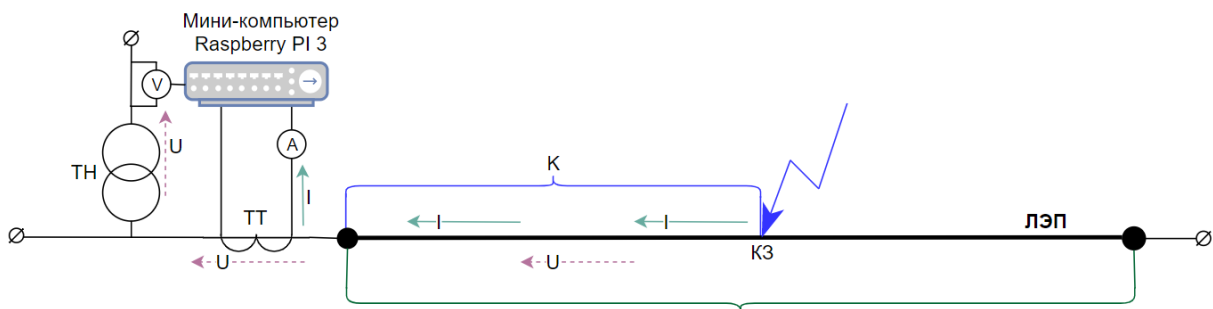


Рис. 5. Принципиальная схема взаимодействия поврежденной ЛЭП и мини-компьютера с предустановленной нейронной сетью
 Fig. 5. Schematic diagram of the interaction of a damaged power line and a mini-computer with a pre-installed neural network

Преобразование значения L в географическую координату (градусы, минуты, секунды) производится на сервере ТСО. Для этого информация о значении L с помощью встроенного GSM модуля с локального мини-компьютера передается на сервер. В соответствии с топологией электрических сетей и

маркером линии, от которой информация поступила на сервер, определяется географическая координата. Впоследствии она отправляется на сервер диспетчерского управления, а далее на компьютер диспетчера, который передает данную информацию оперативно-выездной бригаде (далее – ОВБ).

```

jupyter Neural_LEP1 Last Checkpoint: 15 часов назад (autosaved)
File Edit View Insert Cell Kernel Widgets Help Trusted Python 3 O

pass

In [4]: # количество входных, скрытых и выходных узлов
input_nodes = 5
hidden_nodes = 5
output_nodes = 1

# коэффициент обучения равен 0,4
learning_rate = 0.4

# создать модель нейронной сети по подобию определенных переменных
n = neuralNetwork(input_nodes,hidden_nodes,output_nodes,learning_rate)

In [5]: # загрузите в список тестовый набор данных CSV-файла набора Learn_LEP
data_file = open ("Learn_LEP_withOutputs_1.csv", "r")
data_list = data_file.readlines()
data_file.close()

In [6]: # сколько строк в обучающем массиве
len(data_list)

Out[6]: 3000

In [7]: # проверка значений в n-ой строке массива
data_list[2]

Out[7]: '0.3675, 0.132800, 0.010000, 0.700000, 0.060000, 0.110\n'

In [8]: # тестирование - ввод значений и получение ответа
n.query([0.132800, 0.010000, 0.700000, 0.060000, 0.110])

Out[8]: array([[0.90915199]])

In [9]: # тренировка на обучающем наборе данных
for record in data_list:
# получить список значений, через запятую
all_values = record.split(',')
inputs = numpy.asfarray(all_values[1:])
# получить целевое значение
targets = numpy.asfarray(all_values[0])
n.train(inputs, targets)

In [10]: n.query([0.132800, 0.010000, 0.700000, 0.060000, 0.110])

Out[10]: array([[0.36774926]])

```

Рис. 6. Скриншот Jupyter Notebook отражающий работоспособность кода
 Fig. 6. Screenshot Jupyter Notebook showing the performance of the code

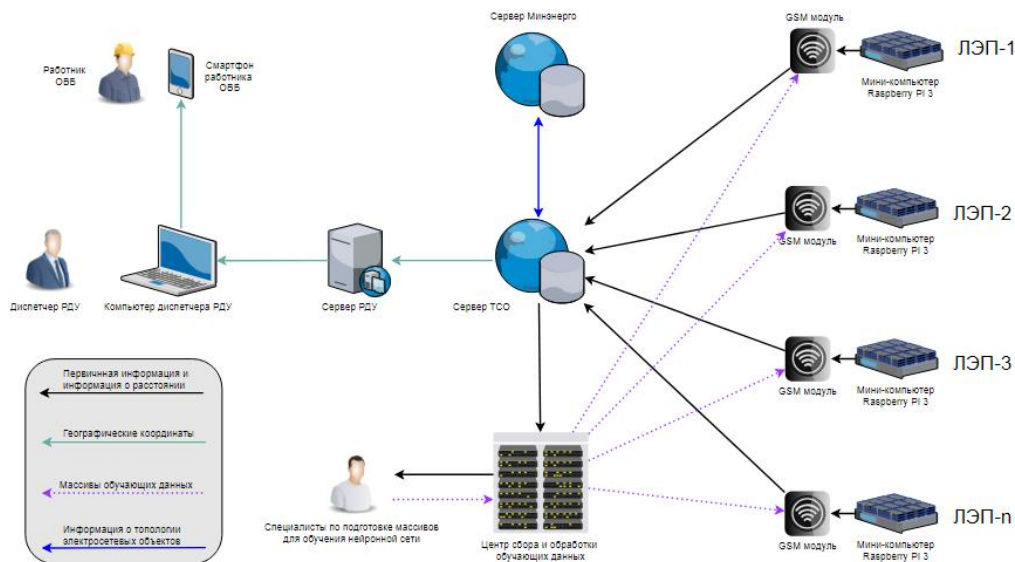


Рис. 7. Организация процесса взаимодействия объектов системы
 Fig. 7. Organization of the process of interaction of system objects

Координаты места повреждения линии электропередачи отображаются на компьютере диспетчера и смартфоне (планшете) работника ОВБ в интерактивном виде.

Разработанный метод обнаружения места повреждения ЛЭП нацелен на повышение надежности системы электроснабжения, а именно на сокращение

времени восстановления нормального режима электроснабжения потребителя. Для того, чтобы определить его целесообразность, необходимо оценить, как изменяется показатель надежности – среднее время восстановления.

$$T_B = \frac{1}{n} \sum_{i=1}^n \tau_i \quad (7)$$



Рис. 8. Пример визуального отображения координат места повреждения ЛЭП на экране компьютера диспетчера и экране смартфона работника ОВБ

Fig. 8. An example of a visual display of the coordinates of the location of damage to power lines on the computer screen of the dispatcher and on the screen of the OVB employee's smartphone

Показатель надежности «среднее время восстановления» улучшился на 100 мин 48 с пропорционально уровню точности нейронной сети, предназначенной для обнаружения места повреждения.

По результатам тестирования опытного образца на реальном примере рассчитана экономическая эффективность и проведено сравнительное технико-экономическое обоснование применения разработанного метода с предложениями, уже существующими на рынке. В качестве примера предложений, реализуемых на рынке в настоящее время, были выбраны устройства отечественного производства, являющиеся лучшими в соотношении точности и доступности. Устройства позволяют определять место повреждения воздушных и воздушно-кабельных линий электропередачи с точностью 80% и 99% соответственно.

На основании технико-экономического сделан вывод о том, что разработанный метод определения места повреждения ЛЭП экономичнее существующего на рынке метода ОМП на 16 %, что пропорционально разности в точности сравниваемых методов.

В заключение можно отметить, что применение технологии нейронных сетей в целях повышения надежности систем электроснабжения путем улучшения количественного показателя надежности «среднее время восстановления» является целесообразным.

СПИСОК ЛИТЕРАТУРЫ

1. Горбунов, И.Н. Комплексное использование Smart Grid и нейронных сетей в целях повышения эффективности эксплуатации систем электроснабжения промышленных предприятий [Текст] /

И.Н. Горбунов / Материалы VI Международной научно-практической конференции «Наука XXI века: проблемы и перспективы» 29-30 мая 2018 г. – г. Уфа / Научно-издательский центр «Ника». – Уфа: Научно-издательский центр «Ника», 2018.

2. Горбунов, И.Н. Применение ЭВМ в целях анализа надежности работы системы электроснабжения в точке потребления электрической энергии [Текст] / И.Н. Горбунов / Материалы Международной научно-практической конференции «Академическая наука в XXI веке: стратегии и тенденции развития» 10-11 сентября 2018 г. – г. Уфа / Научно-издательский центр «Ника». – Уфа: Научно-издательский центр «Ника», 2018.

3. Крылов, В.В. Большие данные и их приложения в электроэнергетике / В.В. Крылов, С.В. Крылов: НИЭ ВШЭ, 2015 – 147 с.: ил.

4. Основные положения концепции интеллектуальной энергосистемы с активно-адаптивной сетью [Текст]. – Москва: Открытое акционерное общество «Федеральная сетевая компания; 2012 – 51 с.

5. Rashid, T. Make Your Own Neural Network / T. Rashid: CreateSpace Independent Publishing Platform, USA, 2016 – 272 p.: im.

6. Созыкин, А.В. Обзор методов обучения глубоких нейронных сетей [Текст] / А.В. Созыкин / Вестник ЮУрГУ. Серия: Вычислительная математика и информатика, 2017.

7. Hinton G.E., Osindero S., Teh Y.-W. A Fast Learning Algorithm for Deep Belief Nets / Neural Computing. 2006. Vol. 18, No. 7. P. 1527–1554. DOI: 10.1162/neco.2006.18.7.1527.

8. LeCun Y., Bottou L., Orr G.B. Efficient Back-Prop / Neural Networks: Tricks of the Trade. 1998. P. 9–50. DOI: 10.1007/3-540-49430-8_2.

9. Costa M. Pasero E. Piglione F. Radasanu D. Short Term Load Forecasting in Using A Synchronously Operated Recurrent Neural Network [Text] / IJCNN99 (1999 International Joint Conference on Neural networks), Washington, USA, 1999
10. Kohonen T. Correlation Matrix Memories // IEEE Transactions on Computers. 1972. Vol. 100, No. 4. P. 353–359. DOI: 10.1109/tc.1972.5008975.
11. Hochreiter S., Bengio Y., Frasconi P., et al. Gradient Flow in Recurrent Nets: the Difficulty of

Learning Long-Term Dependencies // A Field Guide to Dynamical Recurrent Neural Networks. Wiley-IEEE Press. 2001. P. 237–243. DOI: 10.1109/9780470544037.ch14.

12. Moller, M.F. Exact Calculation of the Product of the Hessian Matrix of Feed-Forward Network Error Functions and a Vector in O(N) Time. Computer Science Department, Aarhus University, Denmark. 1993. No. PB-432. DOI: 10.7146/dpb.v22i432.6748.

Igor N. Gorbunov, student, **Sergey G. Zakharenko**, Associate Professor, **Sergey A. Zakharov**, Associate Professor, **Tatyana F. Malakhova**, Associate Professor

T.F. Gorbachev Kuzbass State Technical University, 28, street Vesennyaya, Kemerovo, 650000, Russia

APPLICATION OF NEURAL NETWORKS FOR DETERMINING THE LOCATION OF DAMAGE TO AIR AND CABLE ELECTRICAL TRANSMISSION LINES

Abstract: *The level of development of the electric grid complex is one of the most important indicators of the level of development not only of the state's electric power industry, but also of the economy as a whole. The electric power industry is developing largely due to innovative, breakthrough technologies that scientists have discovered and successfully used in other sectors of the economy. In order to keep up with the technical progress, electric power industry is forced to adapt and to work in advance, taking into account the course of the future development of breakthrough, innovative technologies, preparing the ground for their direct implementation. In this paper, we will assess the possibility of applying big data technologies, machine learning and neural networks in order to increase the reliability of the power supply system of the territorial grid organization (hereinafter referred to as TSS). Also, we will show what must be done to enable further application of these technologies in the conditions of the Kemerovo Region and Russia. This will positively affect the reliability of power supply to consumers.*

Keywords: *electric power system, fault location, artificial neural network.*

Article info: received October 01, 2019
DOI: 10.26730/1816-4528-2019-3-48-55

REFERENCES

1. Gorbunov, I.N. Integrated use of Smart Grid and neural networks in order to improve the efficiency of operation of power supply systems of industrial enterprises [Text] / I.N. Gorbunov / Proceedings of the VI International Scientific Practical Conference "Science of the XXI Century: Problems and Prospects" May 29-30, 2018 - Ufa / Nika Scientific-Publishing Center. - Ufa: Nika Scientific Publishing Center, 2018.
2. Gorbunov, I.N. The use of computers to analyze the reliability of the power supply system at the point of consumption of electric energy [Text] / I.N. Gorbunov / Proceedings of the International Scientific and Practical Conference "Academic Science in the XXI Century: Strategies and Development Trends" September 10-11, 2018 - Ufa / Nika Scientific and Publishing Center. - Ufa: Nika Scientific Publishing Center, 2018.
3. Krylov, V.V. Big data and their applications in electric power industry / V.V. Krylov, S.V. Krylov: Higher School of Economic Research, 2015 - 147 pp., Ill.
4. The main provisions of the concept of an intelligent power system with an active-adaptive network [Text]. - Moscow: Federal Grid Company; 2012 - 51 s.
5. Rashid, T. Make Your Own Neural Network / T. Rashid: CreateSpace Independent Publishing Platform, USA, 2016 - 272 p. : im.
6. Sozykin, A.V. Review of teaching methods for deep neural networks [Text] / A.V. Sozykin / Bulletin of SUSU. Series: Computational Mathematics and Computer Science, 2017.
7. Hinton G.E., Osindero S., Teh Y.-W. A Fast Learning Algorithm for Deep Belief Nets / Neural Computing. 2006. Vol. 18, No. 7. P. 1527-1554. DOI: 10.1162 / neco.2006.18.7.1527.
8. LeCun Y., Bottou L., Orr G.B. Efficient Back-Prop / Neural Networks: Tricks of the Trade. 1998. P. 9–50. DOI: 10.1007 / 3-540-49430-8_2.
9. Costa M. Pasero E. Piglione F. Radasanu D. Short Term Load Recycling Neural Network [Text] / IJCNN99 (1999 International Joint Conference on Neural Networks), Washington, USA, 1999

10. Kohonen T. Correlation Matrix Memories // IEEE Transactions on Computers. 1972. Vol. 100, No. 4. P. 353–359. DOI: 10.1109 / tc.1972.5008975.

11. Hochreiter S., Bengio Y., Frasconi P., et al. Gradient Flow in Recurrent Nets: The Long-Term Dependencies // A Field Guide to Dynamic Recurrent

Neural Networks. Wiley-IEEE Press. 2001. pp. 237–243. DOI: 10.1109 / 9780470544037.ch14.

12. Moller, M.F. There is no need to know how to use it. Computer Science Department, Aarhus University, Denmark. 1993. No. PB-432. DOI: 10.7146 / dpb.v22i432.6748.

Библиографическое описание статьи

Горбунов И.Н., Захаренко С.Г., Захаров С.А., Малахова Т.Ф. Применение нейронных сетей в целях определения места повреждения воздушных и кабельных линий электропередачи // Горное оборудование и электромеханика – 2019. – № 4 (144). – С. 48-55.

Reference to article

Gorbunov I.N., Zakharenko S.G., Zakharov S.A., Malakhova T.F. Application of neural networks for determining the location of damage to air and cable electrical transmission lines. Mining Equipment and Electromechanics, 2019, no. 4 (144), pp. 48-55.