

Для цитирования: Методика идентификации технического состояния оборудования электропоездов / Ю. С. Кучеров, Р. В. Допира, А. А. Шведун, Д. В. Ягольников // Вопросы радиоэлектроники. 2020. № 4. С. 48–56. DOI 10.21778/2218-5453-2020-4-48-56  
УДК 004.896

**Ю. С. Кучеров<sup>1</sup>, Р. В. Допира<sup>1</sup>, А. А. Шведун<sup>2</sup>, Д. В. Ягольников<sup>2</sup>**

<sup>1</sup> АО «Научно-исследовательский институт вычислительных комплексов им. М. А. Карцева», <sup>2</sup> Военная академия воздушно-космической обороны им. Г. К. Жукова

# МЕТОДИКА ИДЕНТИФИКАЦИИ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ОБОРУДОВАНИЯ ЭЛЕКТРОПОЕЗДОВ

*В связи с тем, что оборудование современных электропоездов функционально и технологически усложняется, возрастает актуальность создания бортовых систем предиктивного мониторинга для идентификации их фактического и прогнозируемого технического состояния. В настоящее время такие системы пока не созданы. Одним из возможных путей решения данной задачи можно считать применение нейросетевых технологий. В статье предлагается методика идентификации технического состояния оборудования электропоездов с использованием технологий искусственных нейронных сетей, которая позволяет в режиме реального времени обнаруживать возникновение и развитие неисправностей с отображением информации на дисплее в кабине машиниста. С учетом специфики решаемой задачи обоснован выбор многослойной архитектуры нейронной сети прямого распространения. Все слои нейронной сети являются полностью взаимосвязанными, при этом определено количество нейронов входного и выходного слоев сети, равное числу контролируемых параметров технического состояния электропоезда и числу его возможных технических состояний соответственно. В качестве функции активации нейронов сети выбрана логистическая функция. Для обучения искусственной нейронной сети применяется эвристический подход.*

**Ключевые слова:** искусственные нейронные сети, мониторинг технического состояния, бортовая система мониторинга

## Введение

В современных условиях, когда огромное внимание уделяется безопасности пассажиров, а также предотвращению аварий и крушений электропоездов, к надежности их оборудования предъявляются особенно высокие требования. Для непрерывного мониторинга и анализа технического состояния оборудования электропоездов необходимы бортовые системы, работающие с высокой достоверностью в режиме реального времени.

Анализ существующих решений для мониторинга оборудования электропоездов [1] показал необходимость разработки универсальных бортовых систем, обеспечивающих требуемые уровни полноты охвата устройств, глубины поиска мест отказов и достоверности контроля технического состояния. Одним из возможных путей решения данной задачи является использование нейросетевых технологий [2]. Ряд авторов исследовали эти вопросы [1–6], однако, в настоящее время нет единой методики, позволяющей решить задачу идентификации технического состояния электропоездов в процессе их эксплуатации.

В статье предлагается методика идентификации технического состояния оборудования электропоездов, основанная на применении нейросетевых технологий [3, 6]. Она позволяет осуществлять

идентификацию фактического технического состояния оборудования поездов на основе результатов измерений диагностируемых параметров, полученных от датчиков различных видов.

## Методика идентификации технического состояния оборудования электропоездов: общие положения

Структурно-логическая схема методики идентификации технического состояния оборудования электропоездов представлена на рис. 1.

При рассмотрении методики следует учитывать, что техническое состояние оборудования поездов описывается совокупностью определяющих его диагностических параметров. Разумеется, множество параметров, характеризующих техническое состояние конкретно выбранного оборудования, может быть различным. В первую очередь оно определяется особенностями оборудования. Для обеспечения требуемой наблюдаемости технического состояния электропоездов результаты измерений диагностических параметров могут быть получены с различного вида датчиков, например датчиков вибрации, температуры, постоянного и переменного тока, контроля напряжений, давления и т. д.

Предлагаемая методика может использоваться для определения технического состояния такого

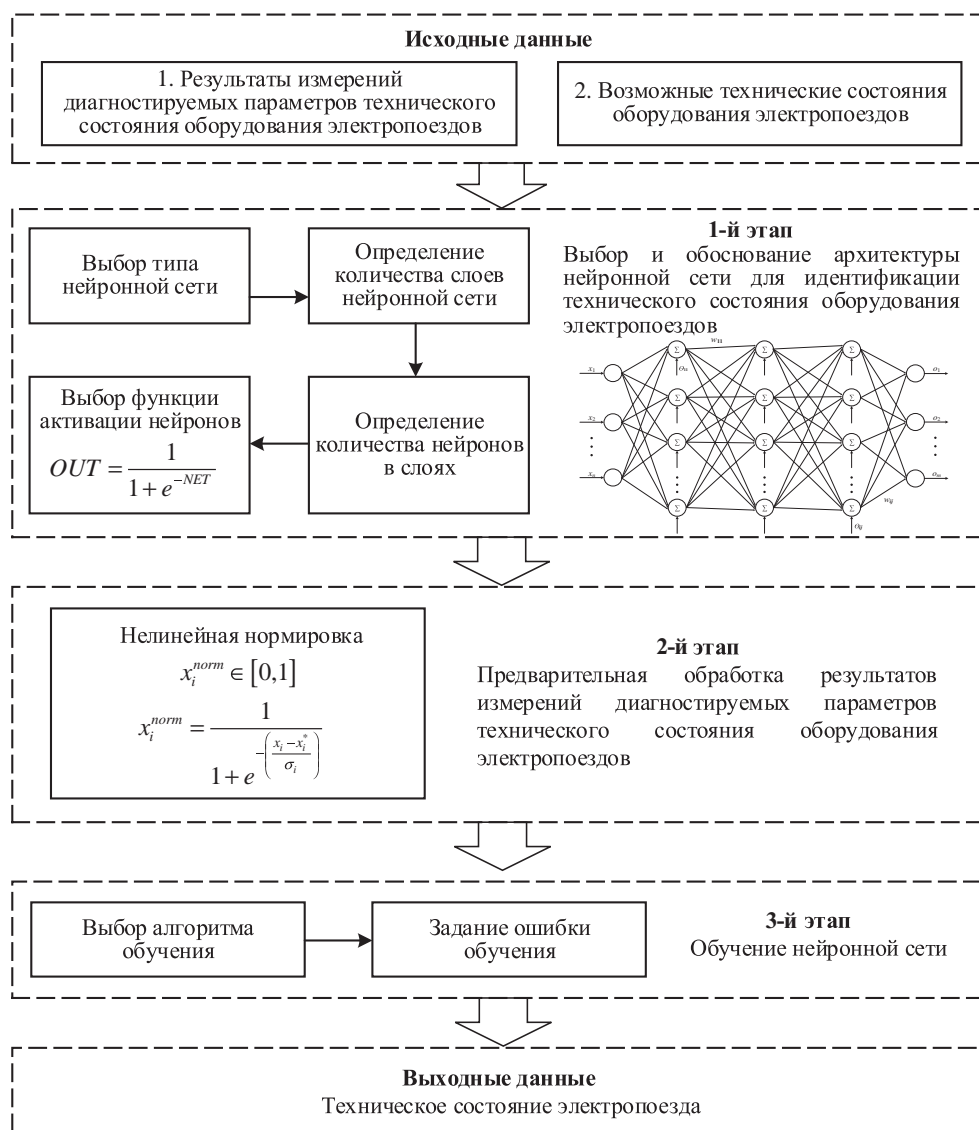


Рисунок 1. Структурно-логическая схема методики идентификации технического состояния оборудования электропоездов

оборудования электропоездов, как механические узлы, электрооборудование, тормозная система и т.д. Однако необходимым условием для корректной работы методики является наличие возможности сбора результатов измерений параметров, характеризующих техническое состояние этого оборудования, а также известный перечень критериев его отказов (неисправностей).

Существенной частью процесса идентификации является выбор диагностических параметров, описывающих техническое состояние электропоезда [7]. В связи с тем, что оптимальный перечень диагностируемых параметров, обеспечивающий наблюдаемость технического состояния оборудования, задает его изготовитель, будем считать, что набор диагностических параметров определен.

Входные данные методики:

- показания измерений диагностируемых параметров электропоездов;
- возможные технические состояния электропоездов, а также критерии отказов (неисправностей) оборудования.

Методика идентификации технического состояния оборудования электропоездов состоит из трех последовательных этапов.

### Первый этап методики

На первом этапе методики необходимо осуществить и обосновать выбор архитектуры нейронной сети и вид функций активации ее нейронов для решения поставленной задачи.

В настоящее время существует огромное число архитектур искусственных нейронных сетей, используемых в различных отраслях науки

и техники [8]. Однако для решения задачи идентификации технического состояния оборудования электропоездов наиболее часто применяются нейронные сети, краткая характеристика архитектур которых [6] представлена в таблице.

Анализ характеристик представленных архитектур искусственных нейронных сетей показал, что требуемой обобщающей способностью и информационной емкостью для осуществления мониторинга технического состояния электропоездов обладают многослойные сети прямого распространения. Недостаток, обусловленный требуемым большим

количеством прецедентов для обучения сети, можно признать незначительным [9].

Таким образом, для решения задачи идентификации технического состояния оборудования электропоездов целесообразен выбор архитектуры многослойной нейронной сети прямого распространения, которая схематично представлена на рис. 2.

На вход сети поступают нормированные значения диагностируемых параметров технического состояния оборудования электропоездов. Количество нейронов входного слоя определяется числом диагностируемых параметров оборудования. За ним

Таблица. Краткая характеристика базовых архитектур искусственных нейронных сетей

Архитектура искусственной нейронной сети	Максимальный объем памяти, ( $K$ – количество запоминаемых прецедентов)	Функции, необходимые при контроле технического состояния	Требуемый объем обучающей выборки	Ограничения и недостатки архитектуры
Многослойная нейронная сеть прямого распространения	$K \gg 2BL$ , $B$ – количество нелинейных преобразователей в слое, $L$ – количество нелинейных преобразований	Распознавание обобщения по подобию, обобщение по преобладанию	Требует большого числа прецедентов	Непрогнозируемое время синтеза классификатора
Нейронная сеть с обратными связями	$K \approx 0,14C$ , $C$ – количество нейронов в сети	Распознавание, выработка прототипа, ассоциативное воспроизведение зашумленных образов	Не требует большого числа прецедентов	Непредсказуемость структуры фазового пространства сети
Самоорганизующиеся слои и карты Кохонена	$K \approx D$ , $D$ – количество нейронов слоя Кохонена	Распознавание и отображение входной информации с сохранением топологии	Не требует большого числа прецедентов	Требует продолжительного обучения




Рисунок 2. Архитектура искусственной нейронной сети для решения задачи идентификации фактического технического состояния электропоездов

следует скрытый слой. Далее данные о техническом состоянии поезда снимают с выходного слоя сети. Количество нейронов выходного слоя определяется числом возможных технических состояний электропоезда.

На рис. 2 использованы следующие обозначения:  $\{x_1, x_2, \dots, x_n\}$  – нормированные значения диагностируемых параметров технического состояния оборудования электропоездов;  $\{w_{11} \dots w_{ij}\}$  – веса между  $i$ -м и  $j$ -м нейронами сети;  $\{\theta_{11} \dots \theta_{ij}\}$  – значения пороговых величин (смещений) в сумматорах нейронов;  $\{o_1, o_2, \dots, o_m\}$  – возможные технические состояния оборудования электропоездов;  $f(\Sigma)$  – функция активации нейронов сети.

Структура элементарных преобразователей (нейронов) сети представлена на рис. 3 [7].

Элементарный преобразователь нейронной сети функционирует следующим образом:

$$NET = \sum x_n w_n,$$

$$OUT = f(NET - \theta),$$

где  $x_n$  – входные данные;  $w_n$  – веса сети;  $NET$  – взвешенная сумма входных данных;  $\theta$  – пороговая величина нейрона.

Для решения поставленной задачи следует выбрать наиболее подходящую функцию активации нейронов. С учетом удобства применения в таких случаях часто используются следующие виды функции активации [3]:

- сигмоида (логистическая функция)

$$OUT = \frac{1}{1 + e^{-\alpha NET}}, \quad (1)$$

где  $\alpha$  – параметр, определяющий наклон функции;

- гиперболический тангенс

$$OUT = \tanh(NET) = \frac{e^{NET} - e^{-NET}}{e^{NET} + e^{-NET}}.$$

Важными положительными качествами сигмоиды являются гладкость и непрерывность функции. Также логистическая функция активации позволяет усиливать слабые сигналы и при этом не насыщаться от сильных. Данными качествами также обладает гиперболический тангенс, однако, эта функция активации является более чувствительной и значительно быстрее насыщается.

Соответственно, учитывая положительные и отрицательные качества рассмотренных функций активации нейронов сети, а также с учетом специфики задачи идентификации технического состояния электропоездов выбрана логистическая функция активации нейронов сети вида (1).

### Второй этап методики

На следующем этапе методики необходимо произвести предварительную обработку результатов измерений диагностируемых параметров технического состояния оборудования электропоездов.

Диагностируемые параметры технического состояния поездов могут иметь различные единицы измерения [6]. В связи с этим для корректной работы искусственной нейронной сети необходимо произвести предварительную обработку диагностируемых параметров, для чего осуществляется нормировка каждого значения параметра. На основе выбранного вида функции активации (1) преобразование результатов измерений параметров в единичный масштаб производится в соответствии с выражениями:

$$x_i^{norm} = \frac{1}{1 + e^{-\left(\frac{x_i - x_i^*}{\sigma_i}\right)}},$$

$$x_i^* = \frac{1}{N_1} \sum_{i=1}^{N_1} x_i,$$

$$\sigma_i^2 = \frac{1}{N_1 - 1} \sum_{i=1}^{N_1} (x_i - x_i^*)^2,$$

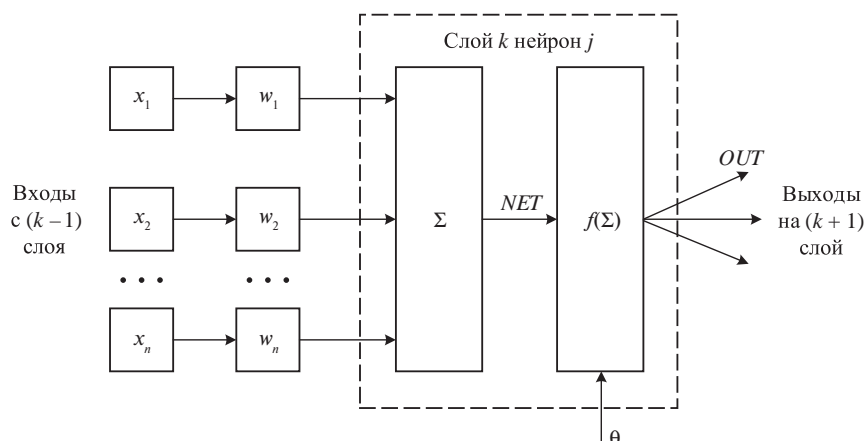


Рисунок 3. Структура искусственного нейрона

где  $x_i^{norm}$  – нормированное значение диагностируемого параметра;  $x_i$  – абсолютное значение параметра;  $x_i^*$  – среднее значение  $i$ -го параметра за  $N_1$  отсчетов;  $\sigma_i$  – среднеквадратическое отклонение значения  $i$ -го параметра за  $N_1$  отсчетов;  $N_1$  – число прецедентов выборки.

### Третий этап методики

На третьем этапе методики необходимо выбрать наиболее подходящий алгоритм обучения искусственной нейронной сети для решения задачи идентификации фактического технического состояния электропоездов и произвести ее обучение.

На данный момент существует множество различных алгоритмов обучения нейронных сетей [10–14]. Наиболее распространенным является алгоритм обратного распространения ошибки обучения сети [3, 10, 11]. Однако с целью уменьшения времени обучения и обеспечения наилучшей сходимости результатов были разработаны улучшающие его эвристики [12, 13]. В [8, 11] показано, что значительное улучшение результативности обучения может быть достигнуто использованием алгоритма Левенберга-Марквардта. Данный алгоритм основывается на стратегии оптимизации Ньютона [13]:

$$p_k = -[H(w_k)]^{-1} g(w_k),$$

где  $p_k$  – направление, обеспечивающее достижение минимального значения целевой функции для данного шага;  $g(w_k)$  – градиент в точке  $w_k$ ;  $H(w_k)$  – матрица Гессе в точке последнего решения  $w_k$ .

Оригинальный алгоритм Левенберга-Марквардта обладает достаточно высокой чувствительностью к локальным минимумам целевой функции. Для устранения данного недостатка предлагается применить эвристический подход, который позволяет «выскочить» из локального минимума функции и продолжить продвижение к новому экстремуму, используя правила оригинального алгоритма. После шести неудачных попыток найденный минимум признается наименьшим, и алгоритм завершает свою работу [13].

Чтобы описать эвристическую модификацию алгоритма Левенберга-Марквардта, представим целевую функцию в следующем виде [6]:

$$E(w_{ij}) = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{pm}^2(w_{ij}), \quad (2)$$

$$e_{pm}(w_{ij}) = d_{pm} - o_{pm}(w_{ij}),$$

где  $d_{pm}$  – учебный (идеальный) выход нейронной сети;  $o_{pm}$  – выход нейронной сети;  $m$  – количество выходов,  $m = \overline{1, M}$ ;  $p$  – количество примеров,  $p = \overline{1, P}$ ;  $w_{ij}$  – веса между  $i$ -м и  $j$ -м элементарными преобразователями.

В ходе реализации алгоритма вычисление матрицы Гессе не осуществляется, что позволяет

снизить объем вычислительных ресурсов при обучении нейронной сети [6]:

$$H = \begin{bmatrix} \frac{\partial^2 E(w_{ij})}{\partial w_1^2} & \frac{\partial^2 E(w_{ij})}{\partial w_1 \partial w_2} & \dots & \frac{\partial^2 E(w_{ij})}{\partial w_1 \partial w_j} \\ \frac{\partial^2 E(w_{ij})}{\partial w_2 \partial w_1} & \frac{\partial^2 E(w_{ij})}{\partial w_2^2} & \dots & \frac{\partial^2 E(w_{ij})}{\partial w_2 \partial w_j} \\ \dots & \dots & \dots & \dots \\ \frac{\partial^2 E(w_{ij})}{\partial w_i \partial w_1} & \frac{\partial^2 E(w_{ij})}{\partial w_i \partial w_2} & \dots & \frac{\partial^2 E(w_{ij})}{\partial w_i \partial w_j} \end{bmatrix}.$$

Необходимо вычислить матрицу, аппроксимирующую матрицу Гессе [6]:

$$H(w_{ij}) \approx J^T(w_{ij})J(w_{ij}) + \mu I(w_{ij}), \quad (3)$$

где  $J(w_{ij})$  – матрица Якоби (якобиан);  $J^T(w_{ij})$  – транспонированная матрица Якоби;  $\mu$  – параметр Левенберга-Марквардта (изменяется в процессе оптимизации и является скалярной величиной);  $I(w_{ij})$  – диагональная матрица из элементов главной диагонали произведения матриц  $(J^T(w_{ij})J(w_{ij}))$ .

Якобиан имеет следующий вид:

$$J(w_{ij}) = \begin{bmatrix} \frac{\partial E(w_{ij})}{\partial w_i \partial w_j} \end{bmatrix}. \quad (4)$$

Таким образом, эвристическая модификация алгоритма Левенберга-Марквардта с использованием данных обозначений выглядит следующим образом [6]:

1. Инициализировать случайными числами начальные значения пороговых величин  $\theta_{ij}$ , параметр Левенберга-Марквардта  $\mu$  и веса искусственной нейронной сети  $w_{ij}$ .
2. Произвести вычисление якобиана в соответствии с выражением (4).
3. В соответствии с выражением (3) вычислить матрицу, аппроксимирующую матрицу Гессе.
4. Определить значение изменения весов искусственной нейронной сети по следующему выражению:

$$\Delta w = (J^T(w_{ij})J(w_{ij}) + \mu I(w_{ij}))^{-1} J(w_{ij}) e(w_{ij}).$$

5. Произвести корректировку для  $k + 1$  итерации весов нейронной сети  $w_{k+1} = w_k - \Delta w$ .
6. По формуле (2) вычислить ошибку обучения нейронной сети на  $k + 1$  итерации.
7. Произвести сравнение заданной величины ошибки обучения искусственной нейронной сети  $E_0$  со значением ошибки на  $k + 1$  итерации. Если условие  $E_{k+1} \leq E_0$  выполняется, то обучение сети заканчивается. Если нет, то надо перейти к шагу 8.

8. Значение ошибки обучения нейронной сети на итерации  $k + 1$  сравнить с предыдущим значением ошибки. Если условие  $E_{k+1} > E_k$  выполняется, то надо перейти к шагу 9, в противном случае – к шагу 11.
9. Параметр Левенберга-Марквардта необходимо увеличить в 10 раз:  $\mu := 10\mu$ .
10. Если число неудачных попыток выхода из области локального экстремума целевой функции удовлетворяет условию  $m_i \leq 6$ , то затем надо перейти к шагу 5, если нет, необходимо перейти к шагу 2.

11. Параметр Левенберга-Марквардта необходимо уменьшить в 10 раз  $\mu := \mu/10$  с сохранением весов искусственной нейронной сети на данной итерации  $w_k := w_{k+1}$ . Затем следует перейти к шагу 2.

При достижении заданного значения ошибки обучения искусственной нейронной сети обучение прекращается. Рассмотренный алгоритм обучения нейронной сети представлен на рис. 4. Применение данного эвристического подхода позволяет в отличие от оригинального алгоритма Левенберга-Марквардта и алгоритма градиентного спуска

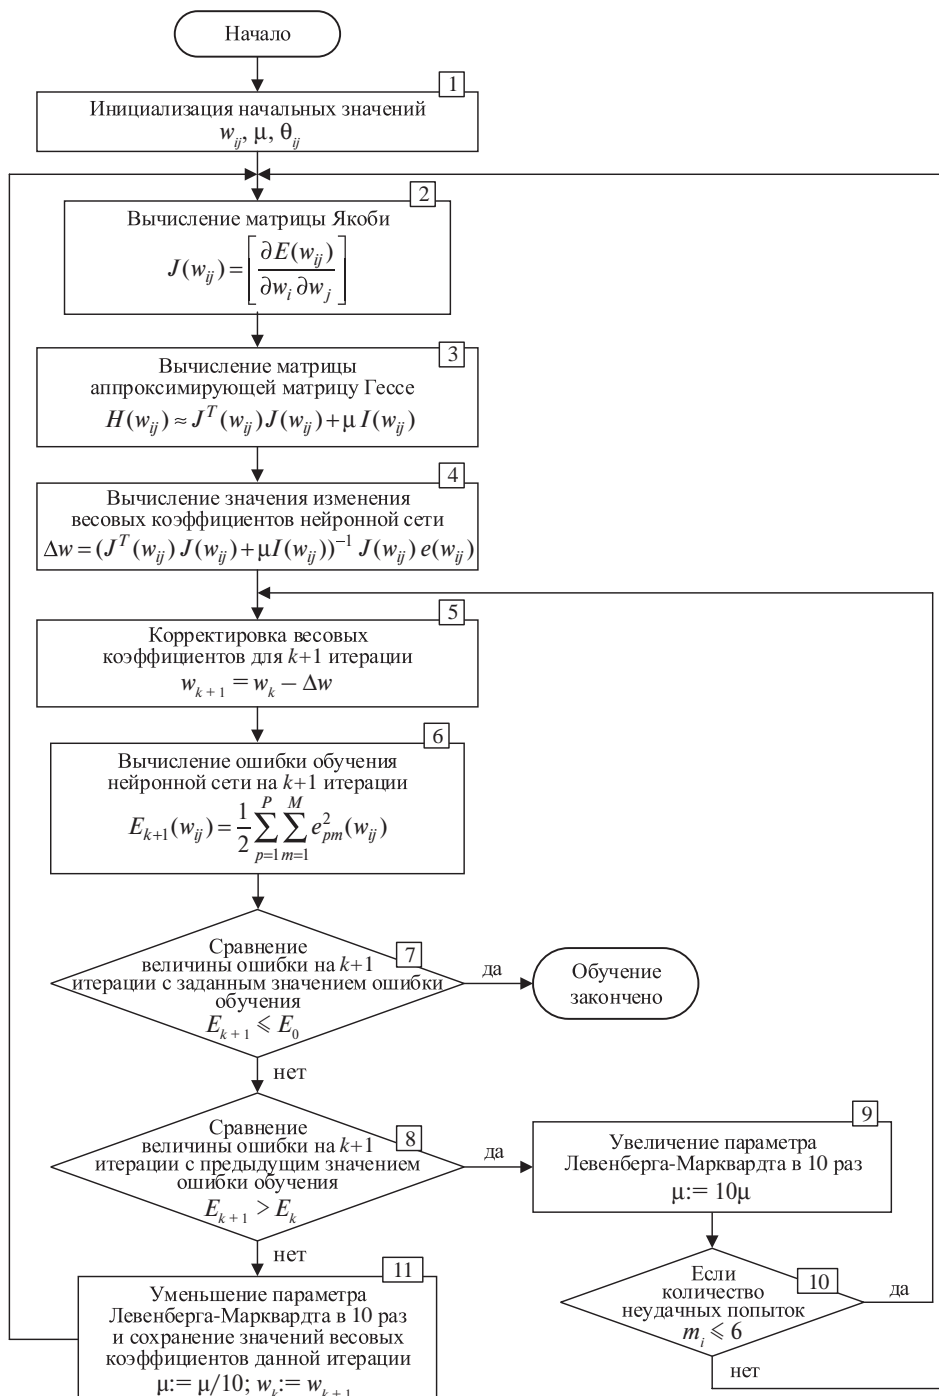


Рисунок 4. Эвристическая модификация алгоритма Левенберга-Марквардта

с обратным распространением ошибки снизить чувствительность к локальным минимумам целевой функции, а также повысить скорость обучения сети [6].

### Заключение

Предложенная методика основана на нейросетевых технологиях, что позволяет производить идентификацию фактического технического состояния электропоездов с требуемым уровнем достоверности. В [15] показана возможность реализации рассмотренной методики в виде технического решения. Программно-аппаратная реализация данной методики позволит получать информацию о текущем техническом состоянии электропоездов в процессе их функционирования

на дисплее бортовых систем мониторинга в кабине машиниста.

В качестве дальнейшего направления исследования может быть рассмотрена методика прогнозирования технического состояния оборудования электропоездов с применением метода сингулярного спектрального анализа для разложения временных рядов, построенных по каждому диагностируемому параметру оборудования поезда, на интерпретируемые аддитивные составляющие и их дальнейшего прогнозирования. После синтеза спрогнозированных составляющих главных компонент временных рядов для идентификации прогнозируемых технических состояний электропоездов предлагается использовать рассмотренную в настоящей работе методику.

### СПИСОК ЛИТЕРАТУРЫ

1. Патент РФ на изобретение № 2386563 / 20.04.2010. Бюл. № 11. Костюков В.Н., Костюков А.В., Бойченко С.Н., Стариков В.А., Зайцев А.В., Щелканов А.В. Система мониторинга электропоездов.
2. Бабокин Г.И., Шпрехер Д.М. Контроль технического состояния электромеханических систем при помощи нейросетевых схем распознавания // Известия Тульского государственного университета. 2010. № 1. С. 109–114.
3. Бабокин Г.И., Шпрехер Д.М. Нейросетевая технология диагностики электромеханических систем горных машин // Известия вузов. Горный журнал. 2011. № 3. С. 39–44.
4. Kiselev M.I., Pronyakin V.I., Tulekbaeva A.K. Technical diagnostics functioning machines and Mechanisms. IOP Conf. Ser.: MSE, 2018, vol. 312.
5. Генов А.А., Русаков К.Д., Хиль С.Ш. Идентификация состояния сложной технической системы в условиях неопределенности измерительной информации // Программные продукты и системы. 2017. Т. 30. № 3. С. 373–377.
6. Метод идентификации технического состояния радиотехнических средств с применением технологий искусственных нейронных сетей / Р.В. Допира, А.А. Шведун, Д.В. Ягольников, И.Е. Яночкин // Программные продукты и системы. 2019. Т. 32. № 4. С. 628–638.
7. Русаков К.Д., Хиль С.Ш. О задаче выбора признаков наблюдаемого состояния сложного динамического объекта в условиях различного качества измерительной информации. Нейрокомпьютеры и их применение: тез. докл. XV Всерос. науч. конф. М.: Изд-во МГППУ, 2017. С. 246–248.
8. Хайкин С. Нейронные сети: полный курс. М.: Вильямс, 2006. 1104 с.
9. Пекунов В.В. Извлечение информации из нейронных сетей прямого распространения в виде простых алгебраических моделей // Информационные технологии. 2017. Т. 23. № 1. С. 76–80.
10. Rumelhart D.E., Hinton G.E., Williams R.J. Learning internal representations by error propagation, in parallel distributed processing. Cambridge, MA, MIT Press, 2011. Vol. 1, pp. 318–362.
11. Теория и практика машинного обучения / В.В. Воронина, А.В. Михеев, Н.Г. Ярушкина, К.В. Святов. Ульяновск: Изд-во УлГТУ, 2017. 290 с.
12. Samad T. Back-propagation improvements based on heuristic arguments. proceedings of international joint conference on neural networks. Washington, 1990. Vol. 1, pp. 565–568.
13. Махотило К.В., Вороненко Д.И. Модификация алгоритма Левенберга-Марквардта для повышения точности прогностических моделей связанного потребления энергоресурсов в быту // Вестник Национального технического университета Харьковский политехнический институт. Серия: Информатика и моделирование. 2005. С. 83–90.
14. Жуков Д.А., Клячкин В.Н. Влияние объема контрольной выборки на качество диагностики состояния технического объекта // Автоматизация процессов управления. 2018. № 2. С. 90–95.
15. Полезная модель к патенту РФ № 194498 / 12.12.2019. Бюл. № 35. Шведун А.А., Ягольников Д.В., Солдатенко В.А., Созонтов И.А. Искусственная нейронная сеть для идентификации технического состояния радиотехнических средств.

### ИНФОРМАЦИЯ ОБ АВТОРАХ

**Кучеров Юрий Сергеевич**, к.т.н., генеральный директор, АО «Научно-исследовательский институт вычислительных комплексов им. М.А. Карцева», Российская Федерация, 117437, Москва, ул. Профсоюзная, д. 108, тел.: 8 (495) 330-09-29, e-mail: postoffice@niivk.ru.

**Допира Роман Викторович**, д.т.н., профессор, ведущий научный сотрудник, АО «Научно-исследовательский институт вычислительных комплексов им. М.А. Карцева», Российская Федерация, 117437, Москва, ул. Профсоюзная, д. 108, тел.: 8 (495) 330-09-29, e-mail: rvdopira@yandex.ru.

**Шведун Андрей Александрович**, адъюнкт, Военная академия воздушно-космической обороны им. Г.К. Жукова, Российская Федерация, 170100, Тверь, ул. Жигарева, д. 50, e-mail: ashvedun@mail.ru.

**Ягольников Дмитрий Владимирович**, к. т. н., докторант, Военная академия воздушно-космической обороны им. Г. К. Жукова, Российская Федерация, 170100, Тверь, ул. Жигарева, д. 50, тел.: 8 (4822) 34-71-97, e-mail: yagolnikov\_dv@mail.ru.

*For citation: Kucherov Y. S., Dopira R. V., Shvedun A. A., Yagolnikov D. V. Method of identification of technical condition of equipped train equipment. Issues of radio electronics, 2020, no. 4, pp. 48–56. DOI 10.21778/2218-5453-2020-4-48-56*

**Y. S. Kucherov, R. V. Dopira, A. A. Shvedun, D. V. Yagolnikov**

## **METHOD OF IDENTIFICATION OF TECHNICAL CONDITION OF EQUIPPED TRAIN EQUIPMENT**

Due to the fact that the equipment of modern electric trains is functionally and technologically complicated, the relevance of creating airborne systems for predictive monitoring of the technical condition of trains to identify their actual and predicted technical condition is increasing. At present, it has not been possible to build automatic on-board systems for predictive monitoring of the technical condition of trains. One of the possible solutions to this problem can be considered the creation of on-board systems, the identification of the technical condition of equipment in which is carried out using neural network technologies. The article proposes a methodology for identifying the technical condition of electric train equipment using artificial neural network technologies, which allows real-time detection of the occurrence and development of malfunctions of electric train equipment with the display of information on the display in the driver's cab. Taking into account the specifics of the problem being solved, the choice of a multilayer architecture of a direct distribution neural network is justified. All layers of the neural network are completely interconnected, while the number of neurons of the input and output layers of the network is determined, equal to the number of controlled parameters of the technical condition of the electric train and the number of its possible technical conditions, respectively. As a function of activation of network neurons, a logistic function was selected. A heuristic approach is used to train an artificial neural network.

**Keywords:** artificial neural networks, monitoring of technical condition, on-board monitoring system

## **REFERENCES**

1. Kostyukov V. N., Kostyukov A. V., Boychenko S. N., Starikov V. A., Zaitsev A. V., Shchelkanov A. V., inventors. System of electric trains monitoring. Russian patent RU2386563. 2010, April 20.
2. Babokin G. I., Shpreher D. M. Control of the technical condition of electromechanical systems using neural network recognition schemes. *Izvestiya Tulkogo gosudarstvennogo universiteta*, 2010, no. 1, pp. 109–114. (In Russian).
3. Babokin G. I., Shpreher D. M. Neural network technology for the diagnosis of electromechanical systems of mining machines. *Izvestiya vuzov. Gornyi zhurnal*, 2011, no. 3, pp. 39–44. (In Russian).
4. Kiselev M. I., Pronyakin V. I., Tulekbaeva A. K. Technical diagnostics functioning machines and Mechanisms. IOP Conf. Ser.: MSE, 2018, vol. 312.
5. Genov A. A., Rusakov K. D., Gil S. Sh. Identification of the state of a complex technical system in the conditions of uncertainty of measurement information. *Programmnye produkty i sistemy*, 2017, vol. 30, no. 3, pp. 373–377. (In Russian).
6. Dopira R. V., Shvedun A. A., Yagolnikov D. V., Yanochkin I. E. A method for identifying the technical state of radio equipment using artificial neural network technologies. *Programmnye produkty i sistemy*, 2019, vol. 32, no. 4, pp. 628–638. (In Russian).
7. Rusakov K. D., Gil S. Sh. On the problem of choosing the features of the observed state of a complex dynamic object in conditions of different quality of measuring information. (Conference proceedings) *Neirokomp'yutery i ikh primeneniye*, XV Vseros. nauch. konf., Moscow, 2017, pp. 246–248. (In Russian).
8. Haykin S. *Neural networks: a comprehensive foundation*. 2<sup>nd</sup> ed. Prentice Hall, 1998, 842 p.
9. Pekunov V. V. Information extraction from direct distribution neural networks in the form of simple algebraic models. *Informatsionnye tekhnologii*, 2017, vol. 23, no. 1, pp. 76–80. (In Russian).
10. Rumelhart D. E., Hinton G. E., Williams R. J. *Learning internal representations by error propagation, in parallel distributed processing*. Cambridge, MA, MIT Press, 2011, vol. 1, pp. 318–362.
11. Voronin V. V., Mikheev A. V., Yarushkina N. G., Svyatov K. V. *Teoriya i praktika mashinnogo obucheniya* [Theory and practice of machine learning]. Ulyanovsk, UIGTU Publ., 2017, 290 p. (In Russian).
12. Samad T. Back-propagation improvements based on heuristic arguments. Proceedings of international joint conference on neural networks, Washington, 1990, vol. 1, pp. 565–568.
13. Makhotilo K. V., Voronenko D. I. Modification of the Levenberg–Marquardt algorithm to improve the accuracy of prognostic models of connected consumption of energy resources in everyday life. *Vestnik Natsionalnogo tekhnicheskogo universiteta Kharkovskii politekhnicheskii institut. Seriya: Informatika i modelirovanie*, 2005, pp. 83–90. (In Russian).
14. Zhukov D. A., Klyachkin V. N. Influence of the volume of the control sample on the quality of diagnostics of the state of a technical object. *Avtomatizatsiya protsessov upravleniya*, 2018, no. 2, pp. 90–95. (In Russian).
15. Shvedun A. A., Yagolnikov D. V., Soldatenko V. A., Sozontov I. A., inventors. Artificial neural network for identification of the technical state of radio equipment. Russian patent RU194498. 2019. December 12.

## **AUTHORS**

**Kucherov Yuri**, Ph. D., general director, M. A. Kartsev Computing System Research and Development Institute (NIIVK, JSC), 108, Profsoyuznaya St., Moscow, 117437, Russian Federation, tel.: +7 (495) 330-09-29, e-mail: postoffice@niivk.ru.



**Dopira Roman**, D. Sc., professor, leading researcher, M.A. Kartsev Computing System Research and Development Institute (NIIVK, JSC), 108, Profsoyuznaya St., Moscow, 117437, Russian Federation, tel.: +7 (495) 330-09-29, e-mail: rvdopira@yandex.ru.

**Shvedun Andrey**, adjunct, G.K. Zhukov Military Academy of Aerospace Defense, 50, Zhigareva St., Tver, 170100, Russian Federation, e-mail: ashvedun@mail.ru.

**Yagolnikov Dmitry**, Ph. D., doctoral candidate, G.K. Zhukov Military Academy of Aerospace Defense, 50, Zhigareva St., Tver, 170100, Russian Federation, tel.: +7 (4822) 34-71-97, e-mail: yagolnikov\_dv@mail.ru.