

СОВЕРШЕНСТВОВАНИЕ АЛГОРИТМОВ МАШИННОЙ КЛАССИФИКАЦИИ СОСТОЯНИЙ РЕЛЬСОВЫХ ЭЛЕКТРОТЕХНИЧЕСКИХ СИСТЕМ В СОСТАВЕ АВТОМАТИЧЕСКОЙ ЛОКОМОТИВНОЙ СИГНАЛИЗАЦИИ

Рельсовые электротехнические системы в составе автоматической локомотивной сигнализации могут находиться в одном из трех состояний, каждое из которых соответствует определенным требованиям по безопасности движения поездов. Переход рельсовой электротехнической системы в очередное состояние возможен при передаче по рельсам соответствующего электрического сигнала числового кода. Существенной проблемой, приводящей к сбоям в работе рельсовых электротехнических систем, являются случайные помехи в интервальных частях электрических сигналов числового кода. Такие помехи приводят к нарушению работы систем автоматической локомотивной сигнализации, задержкам в движении поездов и снижению экономической эффективности перевозочного процесса. В статье предложен способ повышения устойчивости рельсовой электротехнической системы к искажениям электрических сигналов числового кода за счет применения искусственной нейронной сети для определения состояния рельсовой электротехнической системы. Показаны основные преимущества предложенного способа по отношению к имеющимся разработкам в рамках рассматриваемой задачи. Авторами продемонстрирована вычислительная эффективность предлагаемого подхода, которая достигается за счет конвейерной обработки данных.

Ключевые слова: рельсовая электротехническая система, автоматическая локомотивная сигнализация, искусственная нейронная сеть, числовой код, об-
лачные вычисления.

Введение. На железных дорогах России движение поездов по перегонам и станциям осуществляется при помощи систем автоматической локомотивной сигнализации (например, АЛСН, АЛС-О, АЛС-ЕН и др. [1]).

Данные системы функционируют на основе информации о состоянии рельсовых электротехнических систем (РЭС), находящихся в их составе. В зависимости от состояния РЭС система автоматической локомотивной сигнализации выбирает условия ведения поезда по участку с соблюдением правил безопасности движения согласно [2–4].

РЭС может находиться в одном из трех состояний: «З», «Ж» или «КЖ». Переход в очередное состояние определяется типом циклически передаваемого по РЭС электрического сигнала числового кода («З», «Ж» или «КЖ») [5]. Так, например, при передаче электрического сигнала числового кода типа «З» РЭС переходит в состояние «З» (для состояний «Ж» и «КЖ» — аналогично).

Одной из существенных проблем, вызывающих сбои в работе РЭС при определении их состояний, является случайным образом возникающая зашум-

ленность электрических сигналов числового кода. В результате подобных сбоев происходит нарушение функциональной безопасности РЭС, а также снижение экономической эффективности перевозочного процесса [6].

Вопросы повышения стабильности работы РЭС при определении их состояний с учетом специфики автоматической локомотивной сигнализации освещены в работах [7–12]. В некоторых из них, например, в [8, 9], авторами предлагается частичная доработка традиционного алгоритма определения состояния РЭС (на основе релейного дешифратора), а в других — его принципиальные изменения (например, применение корреляционного анализа [11], алгоритмов распознавания изображений [12]).

С учетом современного уровня развития аппаратной части РЭС подход, предложенный в [12], представляется перспективным [13, 14]. В [12] задача определения состояния РЭС решена с применением алгоритмов распознавания изображений на основе искусственной нейронной сети. Ключевым достоинством данного подхода является кор-

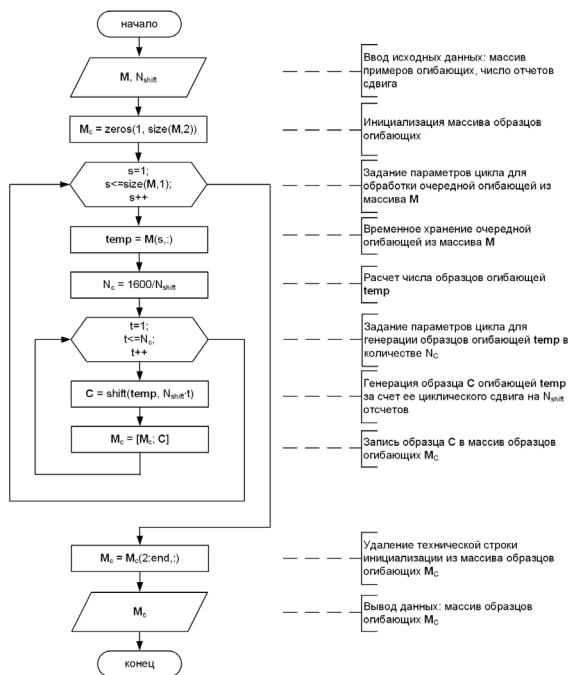


Рис. 1. ГСА модификации обучающей выборки

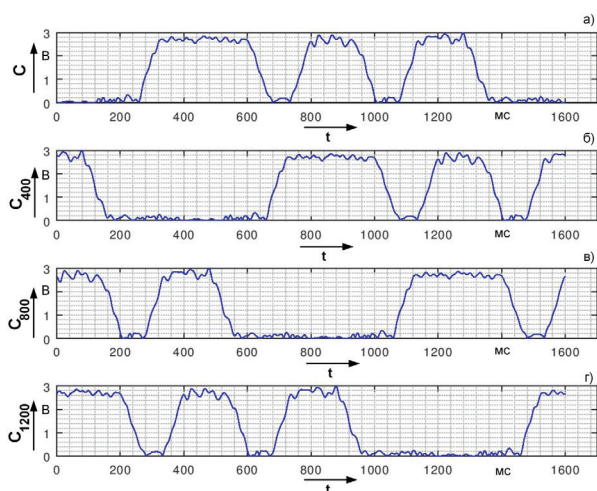


Рис. 2. Огибающая электрического сигнала числового кода «3» (а) и ее образцы (б–г)

ректное определение состояния РЭС даже при зашумленности электрического сигнала числового кода.

В данной статье авторами предлагается совершенствование подхода, представленного в [12], за счет перехода к конвейерной обработке входных данных. Такой тип обработки позволит упростить алгоритм определения состояния РЭС по сравнению с [12] и значительно повысить его вычислительную эффективность за счет:

- отказа от алгоритма синхронизации начала цикла электрического сигнала числового кода;
- уменьшения требуемых ресурсов памяти для буферизации значений входных данных;
- отказа от сложного алгоритма управления процессом определения состояния РЭС.

Формирование обучающей выборки и подбор архитектуры искусственной нейронной сети. Конвейерный тип обработки входных данных

в РЭС подразумевает классификацию ее состояния без предварительного поиска начала цикла электрического сигнала числового кода. Для обеспечения такого режима необходимо, во-первых, провести обучение классификатора на образцах огибающих электрических сигналов числового кода, циклически сдвинутых на различное число отсчетов, то есть модифицировать обучающую выборку из [12], а во-вторых, разработать усложненную архитектуру классификатора, способного различать данные образцы и относить их к одному состоянию РЭС.

В качестве классификатора по аналогии с [12] выбрана искусственная нейронная сеть прямого распространения с одним скрытым слоем [13, 14].

Модификацию обучающей выборки, содержащей примеры, на которых производится обучение искусственной нейронной сети [14], выполним при помощи алгоритма, графическая схема (ГСА) которого показана на рис. 1.

Массив примеров огибающих **M**, содержащий 6000 огибающих электрических сигналов числового кода (3×2000, где 3 — число возможных состояний РЭС, 2000 — число примеров на одно состояние РЭС), а также число отсчетов сдвига N_{shift}, являются входными данными алгоритма (рис. 1).

Очередная огибающая электрического сигнала числового кода из массива **M** записывается во временную переменную **temp**, над которой осуществляются дальнейшие действия в алгоритме.

Огибающая **temp** циклически сдвигается на заданное число отсчетов N_{shift} с целью генерации ее образцов (в ГСА один такой образец обозначен переменной-вектором **C**). Так как огибающая содержит 1600 цифровых отсчетов [12], то число образцов N_c, генерируемых на ее основе, определяется согласно формуле (1):

$$N_c = \frac{1600}{N_{\text{shift}}}. \quad (14)$$

После генерации очередного образца огибающей **C** происходит его запись в массив образцов огибающих **M_c**.

В данном исследовании N_{shift} выбрано равным 100 отсчетам. Тогда массив образцов огибающих **M_c** содержит 96 000 обучающих примеров. Дополним каждый пример массива **M_c** вектором ответов **y**, значения элементов которых соответствуют состоянию РЭС на конкретном обучающем примере. Для состояния «3» значение элемента в **y** примем равным 1, для «Ж» — 2, для «КЖ» — 3.

В качестве примера на рис. 2а показана огибающая электрического сигнала числового кода «3» — **C**. На рис. 2б–г показаны ее образцы **C₄₀₀**, **C₈₀₀** и **C₁₂₀₀**, циклически сдвинутые относительно нее на 400, 800 и 1200 отсчетов соответственно.

Таким образом, модифицированной обучающей выборкой для искусственной нейронной сети является массив образцов огибающих **M_c** и соответствующий ему вектор ответов **y**.

Архитектура искусственной нейронной сети для решения задачи классификации сдвинутых образцов огибающих электрических сигналов числового кода, относящихся к одному состоянию РЭС, требует усложнения по сравнению с [12]. Так как число нейронов во входном и выходном слоях искусственной нейронной сети остается прежним (1600 нейронов во входном слое, 3 нейрона в выходном слое), то непосредственное усложнение архитектуры сети




Рис. 3. Архитектура искусственной нейронной сети

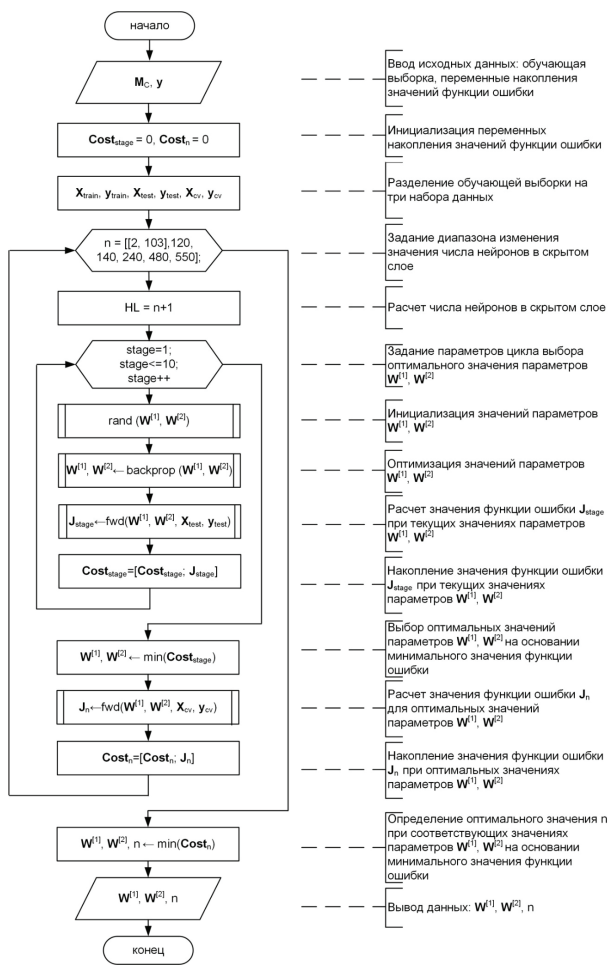


Рис. 4. ГА определения оптимального числа нейронов в скрытом слое

заключается в увеличении размера ее скрытого слоя (рис. 3).

На рис. 3 размерности слоев искусственной нейронной сети показаны снизу под каждым из них соответственно. Слагаемое «+1» учитывает включение базовых нейронов во входной и скрытый слой сети. На рис. 3 базовые нейроны показаны в виде пунктирных окружностей. Они предназначены для удобства вычислительных операций в искусствен-

ной нейронной сети [15]. Значение на выходе базовых нейронов принимается равным единице.

Подбор архитектуры искусственной нейронной сети заключается в определении оптимального значения числа n , что может быть выполнено при помощи алгоритма, ГСА которого показана на рис. 4.

Входными данными алгоритма являются полученные ранее массив образцов обгибающих M_c , вектор ответов y .

Предварительно в алгоритме инициализируются с нулевыми значениями используемые в расчетах переменные-векторы накопления значений функции ошибки $Cost_{stage}$ и $Cost_n$.

Начальным этапом алгоритма (рис. 4) является разделение обучающей выборки на три набора данных $\{X_{train}, y_{train}\}$, $\{X_{test}, y_{test}\}$, $\{X_{cv}, y_{cv}\}$ в пропорциях «60 %» – «20 %» – «20 %» соответственно [14]. Таким образом, набор $\{X_{train}, y_{train}\}$ содержит 57 000 обучающих примеров, $\{X_{test}, y_{test}\}$ – 20 000, $\{X_{cv}, y_{cv}\}$ – 19 000.

Диапазоном значений для n выбран массив [2, 103], [2, 103], [20, 140], [240, 480], [550]. Изначально значение n итеративно изменяется в интервале [2, 103] с шагом приращения, равным 1. Далее за пределами интервала [2, 103] n принимает фиксированные значения 120, 140, 240, 480 и 550. Таким образом, представленному алгоритму с целью поиска оптимальной необходимо перебрать 107 конфигураций скрытого слоя искусственной нейронной сети. Работа внешнего цикла алгоритма заключается в изменении значения n в указанном диапазоне значений. После выбора очередного значения n производится расчет количества нейронов в скрытом слое с учетом базового нейрона.

Внутренний цикл алгоритма предназначен для обучения искусственной нейронной сети сформированной конфигурации.

Последовательность действий во внутреннем цикле является стандартной процедурой и широко применяется при подборе оптимальных значений параметров искусственной нейронной сети [13–18].

Число итераций во внутреннем цикле алгоритма выбрано равным 10. На очередной итерации обучения искусственной нейронной сети (локальная переменная цикла $stage$) последовательно производятся: случайная инициализация параметров $W^{[1]}$, $W^{[2]}$ (дистинг 2 из [12]), их оптимизация (формулы (8)–(18) из [12]) при помощи алгоритма обратного распространения («backprop») [14], [18], вычисление (формулы (7), (12) из [12] – «fwd») и накопление значения функции ошибки J на наборе данных $\{X_{test}, y_{test}\}$ в переменную-вектор $Cost_{stage}$. Последнее необходимо для проверки обобщающей способности искусственной нейронной сети при классификации новых данных [14, 15] на текущей итерации внутреннего цикла алгоритма.

При завершении очередной итерации в переменную-вектор внешнего цикла алгоритма $Cost_n$ записывается значение функции ошибки на наборе данных $\{X_{cv}, y_{cv}\}$. Данный расчет является итоговой метрикой конкретной конфигурации искусственной нейронной сети (при конкретном n), характеризующей ее обобщающую способность. При расчете значения функции ошибки (формулы (7), (12) из [12]) используются параметры $W^{[1]}$, $W^{[2]}$, которым соответствует минимальное значение функции ошибки переменной-вектора $Cost_{stage}$.

Отметим, что использование математических формул для указанных вычислений из [12] возмож-

Технические характеристики виртуальной машины сервиса Yandex Compute Cloud

| Техническая характеристика | Значение |
|------------------------------|---------------------------|
| Платформа | Intel Cascade Lake |
| Тип операционной системы | Linux Ubuntu Server 18.04 |
| Количество ядер CPU | 8 |
| Объем оперативной памяти RAM | 24 Гб |
| Объем дискового пространства | 13 Гб |
| Вычислительная среда | Octave 4.1.1 |

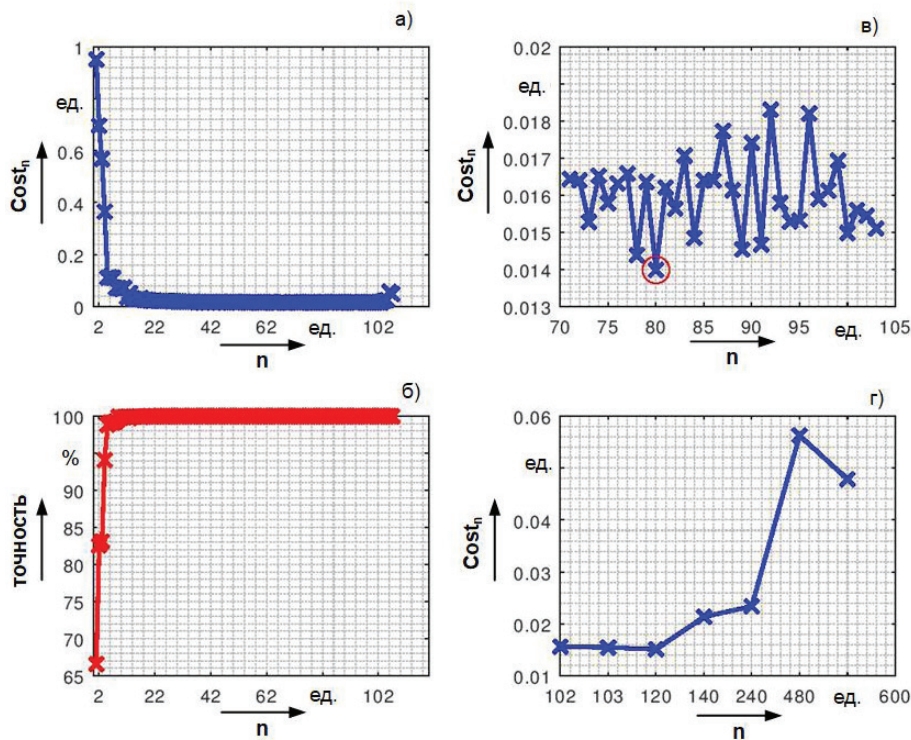


Рис. 5. Графики значений функций ошибки и точности классификатора при различных n (а — график значений функции ошибки; б — график значений точности классификатора; в — масштабированный участок значений функции ошибки при $n \in [70, 103]$; г — масштабированный участок значений функции ошибки при $n \in [102, 103, 120, 140, 240, 480, 550]$)

но по причине их универсальности, обусловленной матричным представлением данных в расчетах.

Последним шагом алгоритма является определение оптимального числа нейронов в скрытом слое искусственной нейронной сети на основании минимального значения функции ошибки в переменном-векторе $Cost_n$. Параметры $W^{(1)}$, $W^{(2)}$, соответствующие оптимальному значению n , выбираются в качестве итоговых для искусственной нейронной сети. Значения $W^{(1)}$, $W^{(2)}$ и n являются выходными данными алгоритма. Подбор оптимальной конфигурации скрытого слоя искусственной нейронной сети согласно алгоритму, приведенному на рис. 4, реализован при помощи вычислительных ресурсов сервиса Yandex Compute Cloud [19]. Обращение к данным ресурсам вызвано ограничениями вычис-

лительных возможностей обычного персонального компьютера. Технические характеристики использованной для вычислений виртуальной машины сервиса Yandex Compute Cloud приведены в табл. 1.

Суммарное время работы виртуальной машины с представленными техническими характеристиками при подборе оптимальной конфигурации скрытого слоя составило 139,9 часов (при последовательном выполнении вычислений).

По результатам реализованных вычислений установлено, что оптимальное число нейронов в скрытом слое искусственной нейронной сети составляет 80. Данное заключение может быть проиллюстрировано графиками на рис. 5.

На рис. 5а показан график значений функции ошибки в зависимости от сложности архитекту-




Рис. 6. Графики осциллограмм электрических сигналов числового кода (а — без искажений; б — с искажениями)

Таблица 2

Затраты времени процессорного устройства на обработку электрических сигналов числового кода

| Электрический сигнал числового кода | Затраты времени для алгоритма из [12], с | Затраты времени для усовершенствованного алгоритма, с |
|-------------------------------------|--|---|
| $S_1[t]$ | 0,734 | 0,075 |
| $S_2[t]$ | 0,839 | 0,097 |

Таблица 3

Технические характеристики вычислительной системы, используемой при обработке $S_1[t]$ и $S_2[t]$

| Техническая характеристика | Значение |
|------------------------------|--|
| Процессорное устройство | AMD FX(tm)-6300 Six-Core Processor, 3500 МГц |
| Объем оперативной памяти RAM | 8 Гб |
| Объем дискового пространства | 7,73 Гб |
| Тип операционной системы | Microsoft Windows 10 Pro |

ры искусственной нейронной сети для всего диапазона значений n . Данные значения, согласно алгоритму, приведенному на рис. 4, фиксировались в переменной-векторе $Cost_n$. На рис. 5б показан соответствующий рис. 4а график изменения точности классификатора. На рис. 5в и 5г показаны масштабированные участки значений функции ошибки при изменении n в диапазонах [70, 103] и [102, 103, 120, 140, 240, 480, 550] соответственно. Как видно из рис. 5в, наименьшее значение функции ошибки наблюдается при 80 нейронах в скрытом слое искусственной нейронной сети (отмечено в виде окружности). На рис. 5г показано, что дальнейшее усложнение архитектуры искусственной нейронной сети приводит к увеличению значения функции ошибки. Таким образом, расчеты по выбору оп-

тимальной архитектуры искусственной нейронной сети показали, что число нейронов в ее скрытом слое следует принять равным 80. Точность классификатора при данной конфигурации на наборе $\{X_{cv}, y_{cv}\}$ составляет 100 %.

Анализ вычислительной эффективности усовершенствованного алгоритма определения состояния РЭС. Продемонстрируем заявленную вычислительную эффективность усовершенствованного алгоритма определения состояния РЭС с конвейерным типом обработки входных данных по сравнению с алгоритмом, представленным в [12]. Для этого передадим на входы каждого из алгоритмов два электрических сигнала числового кода, осциллограммы которых показаны на рис. 6. На рис. 6а приведена осциллограмма сигнала $S_1[t]$, не содер-




Рис. 7. Размеченные осциллограммы электрического сигнала числового кода $S_3[t]$ (а) и его циклически сдвинутых образцов (б–д)




Рис. 8. Размеченные осциллограммы электрического сигнала числового кода $S_4[t]$ (а) и его циклически сдвинутых образцов (б–д)

жащего искажений, а на рис. 6б — сигнала $S_2[t]$, содержащего однократные помехи в интервальных частях электрических сигналов числового кода (показаны пунктирными стрелками). Каждая осциллограмма содержит 24 801 цифровой отсчет.

Вычислительная эффективность предложенного в данной статье алгоритма может быть проиллюстрирована данными из табл. 2, характеризующими затраты времени процессорного устройства при обработке электрических сигналов числового кода (рис. 6) каждым из алгоритмов. Технические характеристики используемой вычислительной системы приведены в табл. 3.

Как видно из данных табл. 2, затраты времени на обработку электрических сигналов числового кода разработанным алгоритмом существенно

меньше (~ в 10 раз), чем для алгоритма из [12], что доказывает целесообразность применения первого при определении состояния РЭС.

Продemonстрируем инвариантность разработанного алгоритма с конвейерным типом обработки входных данных к времени начала очередного цикла электрического сигнала числового кода. Для этого передадим на его вход сигнал $S_3[t]$, не имеющий искажений, а также 4 его образца, циклически сдвинутых друг относительно друга на 400 отсчетов — $S_{31}[t]$, $S_{32}[t]$, $S_{33}[t]$ и $S_{34}[t]$ соответственно. Результат классификации состояний РЭС для каждого из сигналов показан на рис. 7.

Совершим аналогичные действия для электрического сигнала $S_4[t]$ и его образцов $S_{41}[t]$, $S_{42}[t]$, $S_{43}[t]$, $S_{44}[t]$, имеющих однократные помехи в интерваль-

ных частях электрических сигналов числового кода (рис. 8).

Из рис. 7 и 8 видно, что вне зависимости от момента начала обработки входных данных алгоритм успешно классифицирует состояния РЭС по осциллограммам электрических сигналов числового кода. При этом наличие однократных помех в интервальных частях сигналов не приводит к ошибкам (рис. 8). Однако в зонах смены одного вида электрического сигнала числового кода на другой в некоторых случаях наблюдается некорректная работа алгоритма (показано пунктирными прямоугольниками). Данная ситуация возникает вследствие отказа от синхронизации начала очередного цикла электрического сигнала числового кода. В связи с этим с целью предотвращения некорректной работы алгоритма в указанных критических зонах предлагается принимать решение о состоянии РЭС на основе мажоритарного принципа «2 из 3» [20]. Это приведет к тому, что решение о состоянии РЭС будет приниматься по трем, зафиксированным последовательно, циклам электрического сигнала числового кода по принципу большинства.

Заключение. Повышение экономической эффективности перевозочного процесса на железных дорогах требует от систем автоматической локомотивной сигнализации перехода на алгоритмы, реализующие интеллектуальные функции. Разработка таких алгоритмов, апробация и интеграция их в действующие РЭС являются актуальными вопросами научных исследований. В рамках данного направления в статье предложен алгоритм определения состояния РЭС с конвейерной обработкой электрических сигналов числового кода на основе искусственной нейронной сети. Несмотря на усложнение процедуры обучения искусственной нейронной сети на несинхронизированных обучающих примерах, вычислительная эффективность разработанного алгоритма, продемонстрированная в статье, делает целесообразным его применение в эксплуатируемых на железнодорожном транспорте системах автоматической локомотивной сигнализации.

Библиографический список

1. Венцевич Л. Е. Локомотивные устройства обеспечения безопасности движения поездов и расшифровка информационных данных их работы. 2-е изд., стер. М., 2013. 327 с. ISBN 978-5-89035-703-8.
2. Инструкция по сигнализации на железнодорожном транспорте Российской Федерации. Екатеринбург, 2015. 276 с.
3. Правила технической эксплуатации железных дорог Российской Федерации. Екатеринбург, 2016. 272 с.
4. Инструкция по движению поездов и маневровой работе на железнодорожном транспорте Российской Федерации. Екатеринбург, 2016. 416 с.
5. Леонов А. А. Техническое обслуживание автоматической локомотивной сигнализации. 5-е изд., перераб. и доп. М.: Транспорт, 1982. 255 с.
6. Табунщиков А. К., Горенбейн Е. В., Стряпкин Л. И. Сбои АЛСН. Проблемы и пути их решения // Автоматика, связь, информатика. 2015. № 8. С. 21–22.
7. Леушин В. Б., Юсупов Р. Р. Особенности каналов автоматической локомотивной сигнализации магистральных железных дорог. Самара: СамГУПС, 2007. 115 с. ISBN 978-5-98941-065-1.
8. Пат. 2517631 Российская Федерация, МПК В 61 L 25/06. Приемное устройство автоматической локомотивной сигнали-

зации / Лочехин В. С. № 2012129762/11; заявл. 13.07.12; опубл. 20.01.14, Бюл. № 2.

9. Пат. 2618616 Российская Федерация, МПК В 61 L 25/06, Н 04 В 15/00. Устройство подавления импульсных помех на входе локомотивного приемника АЛС / Аргунов И. А., Вихрова Н. Ю., Горенбейн Е. В., Розенберг Е. Н., Табунщиков А. К. № 2015154775, заявл. 21.12.15; опубл. 04.05.17, Бюл. № 13.

10. Юсупов Р. Р. Цифровое устройство обработки сигналов автоматической локомотивной сигнализации повышенной помехозащищенности: дис. ... канд. техн. наук. Самара, 2003. 162 с.

11. Пат. 2314223 Российская Федерация, МПК В 61 L 25/06. Способ дешифрирования сигналов автоматической локомотивной сигнализации и устройство для его реализации / Рабинович М. Д., Никифоров Б. Д., Соколов А. Н., Правдолюб А. Э., Кравцов Ю. А. № 2005123854/11, заявл. 27.07.05; опубл. 10.02.08, Бюл. № 1.

12. Присухина И. В., Борисенко Д. В. Машинная классификация сигналов числового кода в электротехнических системах локомотивной сигнализации // Омский научный вестник. 2019. № 4 (166). С. 39–47. DOI: 10.25206/1813-8225-2019-166-39-47.

13. Chollet F. Deep learning with Python. NY: Manning Publ., 2017. 384 p. ISBN 978-1617294433.

14. Goodfellow I., Bengio Y., Courville A. Deep learning. Cambridge, Massachusetts: MIT Press, 2016. 775 p. ISBN 978-0262035613.

15. Hastie T. The elements of statistical learning. 2nd ed. NY: Springer, 2009. 745 p. ISBN 0387848576, 978-0387848570.

16. Mitchel T. M. Machine learning. NY: McGraw-Hill Science, 1997. 432 p. ISBN 0070428077.

17. Murphy K. P. Machine learning: a probabilistic perspective. Cambridge, Massachusetts: MIT Press, 2012. 1067 p. ISBN 0262018020; 978-0262018029.

18. Bishop C. M. Pattern recognition and machine learning. NY: Springer, 2010. 738 p. ISBN 978-0-387-31073-2.

19. Yandex Compute Cloud. Виртуальные машины и диски. URL: <https://cloud.yandex.ru/services/compute> (дата обращения: 24.10.2019).

20. Сапожников Вал. В., Сапожников Вл. В., Ефанов Д. В. Теория дискретных устройств железнодорожной автоматики, телемеханики и связи. М., 2016. 337 с. ISBN 978-5-89035-900-1.

ПРИСУХИНА Илона Вадимовна, аспирантка кафедры «Автоматика и телемеханика».

SPIN-код: 8429-0259

AuthorID (РИНЦ): 907740

Адрес для переписки: ivpriskuhina@mail.ru

БОРИСЕНКО Дмитрий Владимирович, кандидат технических наук, доцент (Россия), доцент кафедры «Автоматика и телемеханика».

SPIN-код: 9697-9830

AuthorID (РИНЦ): 533908

Адрес для переписки: borisenkodv@yandex.ru

Для цитирования

Присухина И. В., Борисенко Д. В. Совершенствование алгоритмов машинной классификации состояний рельсовых электротехнических систем в составе автоматической локомотивной сигнализации // Омский научный вестник. 2019. № 6 (168). С. 63–69. DOI: 10.25206/1813-8225-2019-168-63-69.

Статья поступила в редакцию 29.10.2019 г.

© И. В. Присухина, Д. В. Борисенко