

Применение LSTM-моделей в задачах моделирования и прогнозирования геометрии рельсовой колеи

В.О. Шарова✉

Научно-исследовательский институт железнодорожного транспорта (ВНИИЖТ), г. Москва, Российская Федерация

✉sharova.valeriia@vniizht.ru

Резюме

В статье описаны актуальные задачи, связанные с диагностикой и безопасностью движения на железнодорожном транспорте, в особенности на железнодорожном пути. Они касаются ускоренных темпов цифровизации железнодорожного транспорта, а также роста экономики и множественных предпосылок представления дополнительных методов оценки состояния пути для принятия более эффективных управленческих решений. Приведены краткие обзоры различных вариантов моделирования в качестве дополнительных методов для решения поставленных задач. Показаны перспективные методы использования нейронных сетей, рассмотрены классы задач, в которых могут быть задействованы нейронные сети, обозначена проблема их применения, а именно отсутствие методологической базы, стандартизирующей работу с нейронными сетями. Отмечено главное условие для использования нейронных сетей – достоверная обучающая выборка. Для примера применения нейронной сети в задаче моделирования геометрии рельсовой колеи выбрана LSTM-модель, описана архитектура данной модели. Смоделированы фактические вертикальные неровности на выбранном участке железнодорожного пути, рассчитаны среднеквадратичные ошибки моделирования. Подчеркнута целесообразность и высокое качество моделирования с помощью LSTM-модели, а также рост значения среднеквадратичной ошибки с увеличением шагов для прогнозирования, что может быть обусловлено недостатком данных для обучающей выборки. В последующих исследованиях планируется сократить количество ошибок и повысить точность модели, а также попробовать в действии другие нейронные сети различной архитектуры для решения аналогичной задачи с последующим сравнением с LSTM-моделью.

Ключевые слова

железнодорожный путь, моделирование, нейронные сети, геометрия рельсовой колеи, неровности пути, LSTM-модель

Для цитирования

Шарова В.О. Применение LSTM-моделей в задачах моделирования и прогнозирования геометрии рельсовой колеи / В.О. Шарова // Современные технологии. Системный анализ. Моделирование. 2024. № 2 (82). С. 89–97. DOI 10.26731/1813-9108.2024.2(82).89-97.

Информация о статье

поступила в редакцию: 15.04.2024 г.; поступила после рецензирования: 22.04.2024 г.; принята к публикации: 24.04.2024 г.

Application of LSTM-models in problems of modeling and forecasting the geometry of a rail track

V.O. Sharova✉

Scientific Research Institute of Railway Transport (VNIIZHT), Moscow, the Russian Federation

✉sharova.valeriia@vniizht.ru

Abstract

Article describes the current tasks related to the diagnosis and safety of traffic on railway transport and, in particular, on the railway track. These tasks are related to the accelerated pace of digitalization of railway transport, as well as to the growth of the economy and to the multiple prerequisites for the presentation of additional methods for assessing the condition of the track to make more effective management decisions. Brief reviews of various modeling options are given as additional methods for solving the tasks set. Promising methods of using neural networks are shown. Classes of tasks in which neural networks can be used are considered. The problem of using neural networks is outlined, namely, the lack of a methodological framework that standardizes the use of neural networks. The main condition for the use of neural networks is a reliable training sample. As an example of using a neural network in the task of modeling the geometry of a rail track, the LSTM model is selected. The architecture of the LSTM model is described. An example of modeling the actual vertical irregularities on a selected section of railway track is presented, and the quadratic modeling errors are calculated. The expediency and high quality of modeling using the LSTM-model are noted, as well as an increase in the value of the mean square error with increasing steps for forecasting, which may be due to an insufficient number of values for the training sample. The continuation of the research will be to achieve lower error values and increase the accuracy of the model, as well as the use of other neural networks of various architectures to solve the problem of modeling the geometry of the rail track with its subsequent comparison to the LSTM model.

Keywords

railway track, modeling, neural networks, track geometry, track irregularities, LSTM-model

For citation

Sharova V.O. Primenenie LSTM-modelei v zadachakh modelirovaniya i prognozirovaniya geometrii rel'sovoi kolei [Application of LSTM-models in problems of modeling and forecasting the geometry of a rail track]. *Sovremennye tekhnologii. Sistemnyi analiz. Modelirovanie* [Modern Technologies. System Analysis. Modeling], 2024, no. 2(82), pp. 89–97. DOI: 10.26731/1813-9108.2024.2(82).89-97.

Article info

Received: April 15, 2024; Revised: April 22, 2024; Accepted: April 24, 2024.

Введение

В современных реалиях, на фоне увеличения темпов роста экономики, повышения осевых нагрузок и увеличения грузонапряженности возникают задачи эффективной и безопасной работы железнодорожного транспорта. Естественно, есть множество факторов, в совокупности влияющих на решение данных задач, такие как состояние подвижных составов, состояние пути, качество содержания пути и т.д. Остановимся на одном из важнейших параметров этой системы – взаимодействие пути и подвижного состава. Для того чтобы узнать достоверные значения показателей взаимодействия пути и подвижного состава, проводятся натурные испытания. К сожалению, натурные испытания дорогостоящи, а также для решения определенного круга задач необходимо проводить большое количество разного рода натурных испытаний, поэтому, учитывая ускоренную цифровизацию различных сфер железнодорожной области, старые методы решения задач частично заменяются и дополняются новыми подходами и методами. К таким методам относятся различные виды моделирования. Использование моделирования на железнодорожном транспорте уже не является неким новым подходом в решении задач, в частности железнодорожного пути, но количество моделей, их различные внутренние алгоритмы, достоверность и другие параметры совершенствуются по мере развития вычислительной техники и баз знаний о различных изменениях состоянии пути во времени. Одними из значимых моделей являются модели геометрии рельсовой колеи. Они позволяют решать широкий круг задач – накопление остаточных деформаций, определение показателей взаимодействия пути и подвижного состава и др. Таким образом, использование различных математических моделей можно ранжировать на три круга широких задач. Первый – это поиск закономерностей про-

цессов и причин их возникновения: при решении таких задач можно использовать спектральный анализ [1], корреляционный анализ и статистический анализ. Второй – расчет заданных показателей в модели, например, показателей взаимодействия пути и подвижного состава. И третий – это прогнозирование, которое также включает в себя предыдущие пункты.

Данная тема еще является актуальной за счет отсутствия в действующей инструкции по состоянию пути учета периодических неровностей пути, возникающих в геометрии рельсовой колеи, влияющих на показатели пути и подвижного состава, что возвращает нас в первый круг задач, при этом нераздельно влияя на все описанные круги задач.

Целью статьи является иллюстрация применения нейронной сети в задачах прогнозирования и моделирования геометрии рельсовой колеи.

В данной работе будет представлен вариант использования LSTM-модели, а также небольшой обзор других вариантов моделей.

Обзор моделей

Главной задачей моделирования является определение выходных заданных параметров различных систем, в качестве исходных данных которых являются характеристики выбранной системы, а также информация о воздействующих на нее внешних факторах. Классическими методами для решения таких задач, используемыми и в настоящее время, являются: математическая статистика, планирование экспериментов, регрессионный анализ, спектральный анализ, методы имитационного и конечно-элементного моделирования. Выбор конкретного метода зависит от поставленной задачи с учетом технологических и физических процессов, протекающих в исследуемом процессе [2]. Примерами классических методов являются авторегрессионные модели и модели векторной

авторегрессии, а также модель авторегрессии проинтегрированного скользящего среднего. Данные модели рассматривают движение подвижного состава по неровностям пути в виде временного ряда.

Широкое распространение еще в середине прошлого века получили авторегрессионные модели и модели векторной авторегрессии [3, 4]. Они до сих пор широко используются, в частности для моделей геометрии рельсовой колеи. Для построения таких моделей важную роль играют расчеты статистических характеристик, а также ограничения, налагаемые при построении такого рода моделей, а именно проверка на стационарность моделируемого процесса.

Более сложной и комбинированной моделью стала ARIMA-модель (AutoRegressive Integrated Moving Average), также известная как AP-ПСС-модель, модель авторегрессии проинтегрированного скользящего среднего. Ее особенностью является добавление к регрессионной модели скользящего среднего. Эта модель используется при анализе нестационарных временных рядов. Применение данной модели позволяет улучшить точность в сравнении с регрессионными моделями, а также, как уже упоминалось, применять ее для нестационарных процессов.

При этом при рассмотрении трудноформализуемых и сложных динамических систем использование классических методов может быть обусловлено большим количеством допущений и низкой точностью полученных расчетов. Решение задач, связанных со сложным описанием динамических систем, подверженных изменению большого количества факторов, а также имеющие несколько параллельно работающих технологических линий, сложно формализовать или описать аналитическими зависимостями. Попыткой решения таких сложных задач явилось создание нейронных сетей на основе машинного обучения. Изначально нейронные сети появились благодаря нейрофизиологии и математической логике. Еще в 1943 г. в трудах Мак-Каллока и Питца описывались принципы и построение искусственных нейронных сетей. В дальнейшем исследования показали способность нейронных сетей к обучению и самообучению. Нейронная сеть представляет собой упрощенную модель обработки информации мозгом, в основе работы которой лежат нейроны (модель физического нейрона), состоящие из синапсов, сумматора и функции активации. Характер рас-

пределения нейронов (количество нейронов, слоев и связи между ними) определяют архитектуру нейронной сети. С точки зрения архитектуры распространенными нейронными сетями являются однослойные и многослойные сети прямого распространения и рекуррентные сети. Сформированная структура нейронной сети является основой для ее обучения. Для обучения нейронной сети необходимо использовать выборку сигналов, полученных на основе реальных данных, чтобы обеспечить максимально точный результат. Это является ключевым фактором для обучения нейронной сети [2].

В общем виде классы задач, для которых могут использоваться нейронные сети [5], следующие:

- моделирование трудноформализуемых систем и управление ими;
- распознавание образов и их классификация;
- анализ временных рядов и прогнозирование.

Выше был также представлен вариант классификации задач применительно к железнодорожному пути. Если сопоставить оба варианта классификации, то можно отметить, что использование нейронных сетей в настоящее время также решает все больше задач, поставленных перед железнодорожной отраслью. Рассмотрим каждый класс задач, для решения которых могут быть использованы нейронные сети применительно для железнодорожного пути.

1. Проблема контроля и технического состояния пути. Использование нейронной сети для распознавания образов и анализа временных рядов, а также прогнозирования. В качестве входных данных могут быть использованы изображения, полученные с камер подвижного состава. В качестве анализа временных рядов могут быть данные процесса движения подвижного состава по неровностям пути, а также дальнейшее прогнозирование состояния пути. Примеры использования представлены в работах [6–8].

2. Проблема автоматизированного управления подвижным составом, потребность автоматического контроля различных систем подвижного состава. Использование систем распознавания образов и машинное зрение также может стать важнейшим помощником в решении данной проблемы. Примеры использования представлены в работах [9–11].

3. *Проблема прогнозирования эксплуатационных показателей.* Актуально прогнозирование грузовых и пассажирских перевозок. Нейронную сеть в данном случае также можно использовать для анализа временных рядов и прогнозирования. Примеры использования представлены в работах [12, 13].

Представленный широкий спектр использования нейронных систем в качестве решений проблем, поставленных перед железнодорожной областью, обусловлен цифровизацией производственных процессов в Российской Федерации, а также трендом в ОАО «РЖД», создающим необходимую технологическую базу для использования нейронных сетей. При всей положительной картине использования нейронных сетей применительно к задачам железнодорожного комплекса отсутствует методологическая база, стандартизирующая использование нейронных сетей. Также отсутствуют стандарты, связанные с верификацией и валидацией математических и имитационных моделей. Поэтому на сегодняшний день использование данных методов моделирования распространено в большинстве своем в научной среде. Возможно с учетом увеличения научных работ на данные темы получится определить нужные стандарты и методологию. В данной статье приведен пример LSTM-модели.

LSTM-модель

Стремительное развитие искусственных нейронных сетей (ИНС) предоставило для математического моделирования геометрии рельсовой колеи принципиально новые решения. Так, один из видов ИНС – рекуррентные нейронные сети (Recurrent Neural Network, RNN), ориенти-

рован на решение задач моделирования направленных последовательностей, таких как естественные языки и временные ряды.

LSTM (LongShort-TermMemory), долгая краткосрочная память – один из видов архитектуры рекуррентной нейронной сети [14], разработанный С. Хохрайтером и Ю. Шмидхубером в 1997 г. [15]. В конструкцию LSTM входят ячейки памяти и механизмы стробирования (выделение некоторого интервала во времени), которые обеспечивают выборочное хранение и извлечение информации в течение длительного времени. Ячейка памяти сохраняет важную информацию с предыдущих временных шагов, позволяя сети распознавать долгосрочные зависимости во входных последовательностях. Механизмы управления, состоящие из элементов ввода, вывода и забывания, регулируют поток информации, поступающей в ячейку памяти и выходящей из нее.

Ячейка LSTM имеет три стробирующих механизма: входной, выходной и блокирующий (рис. 1):

- входной блок определяет, какая информация должна храниться в ячейке;
- функция «забыть» регулирует, какая информация в ячейке сохраняется, а какая забывается;
- выходной элемент определяет, какая информация из ячейки должна быть выведена.

LSTM-модели особенно эффективны в задачах прогнозирующего моделирования, когда входные последовательности связаны с долгосрочными зависимостями и переменной длиной. Это связано с тем, что LSTM-модели могут обрабатывать последовательности переменной длины и хранить информацию в течение дли-




Рис. 1. Ячейка LSTM
Fig. 1. LSTM cell

тельного времени, что позволяет им распознавать сложные закономерности во входных данных. В решении задач, связанных с временными рядами, LSTM-модели показали себя многообещающими в плане выявления сложных взаимосвязей между переменными и составлением точных прогнозов. Изучая корреляции между входными характеристиками и соответствующими им будущими значениями, сети LSTM могут прогнозировать результаты на основе исторических закономерностей. Это особенно полезно при техническом обслуживании и эксплуатации железных дорог, где такие переменные, как геометрические параметры пути, погодные условия, скорость и вес поезда могут повлиять на будущее состояние пути. LSTM-модели могут эффективно отслеживать эти зависимости и делать точные прогнозы, максимально оптимизируя техническое обслуживание пути и повышая безопасность на железных дорогах [16].

Учитывая многообещающие результаты использования LSTM-модели при решении задач, связанных с временными рядами, именно эта модель была выбрана для моделирования неровностей геометрии рельсовой колеи заданного участка. В ходе проведенных исследований при построении LSTM-моделей в качестве исходных данных рассматривались промеры вертикальных неровностей рельсовой колеи Октябрьской и Горьковской железных дорог. В качестве иллюстрирующего примера был выбран 1 032 км Горьковской железной дороги. Длина промера составила 1 км с шагом 18,5 см. На рис. 2 представлены фактические неровности.

Модель LSTM состоит из нескольких уровней, каждый из которых вносит свой вклад в процесс обучения и прогнозирования. На начальных уровнях входные данные объединя-

ются и анализируются совместно для извлечения соответствующих характеристик и выявления общих закономерностей в данных. Этот первоначальный анализ помогает модели выявить общие тенденции и зависимости, характерные для различных объектов, прежде чем переходить к слоям, относящимся к конкретным объектам. После начальных слоев результаты коллективного анализа распределяются по отдельным слоям, каждый из которых посвящен определенному объекту. Эти слои позволяют модели сосредоточиться на уникальных характеристиках и вариациях каждого объекта, что еще больше повышает способность модели учитывать сложность геометрических параметров пути [16].

Настройка и обучение LSTM-модели выполнялись с использованием модели Sequential библиотеки Keras [17, 18]. Вначале, при разработке LSTM-модели, необходимо выполнить ряд подготовительных операций, в частности необходимо сформировать трехмерный входной вектор, который затем передается во входную форму LSTM. Для формирования трехмерного вектора была написана функция с параметром скользящего окна. Значение этого параметра указывало, сколько первых точек (значений) данных будет учитываться в качестве входных данных X_n для прогнозирования следующей, X_{n+1} , точки данных. Затем новое окно со значением X_{n+1} использовалось в качестве входных данных для прогнозирования X_{n+2} точки данных и т.д.

При разработке LSTM было определено, что разрабатываемая модель является последовательной, с входным слоем (60, 1), т.е. программа должна использовать 60 точек (значений) данных для предсказания 61-й точки данных. Также к модели добавляется слой LSTM с




Рис. 2. Фактические неровности 1 032 км (правая нить) Горьковской железной дороги
Fig. 2. Actual unevenness of 1,032 km (right line) of the Gor'kii railway

64 внутренними узлами, два слоя Dense 8 и 1 слой с узлами, отвечающими за соединения нейронов с функциями активации «relu» и «linear» соответственно. Установка параметров разрабатываемой LSTM-модели представлена на рис. 3.

```
Model: "sequential"
-----
Layer (type)                Output Shape          Param #
-----
lstm (LSTM)                  (None, 64)            16896
dense (Dense)                 (None, 8)              520
dense_1 (Dense)              (None, 1)              9
-----
Total params: 17425 (68.07 KB)
Trainable params: 17425 (68.07 KB)
Non-trainable params: 0 (0.00 Byte)
```

Рис. 3. Установка параметров LSTM-модели
Fig. 3. Setting LSTM model parameters

После разработки структуры модели была проведена ее компиляция перед обучением. Потери (loss) при обучении считается среднеквадратичная ошибка, а метрикой (metrics) – среднеквадратичное значение ошибки в корне.

Модель обучалась на 80 встроенных циклах обучения (эпохах). В результате описанных ранее выполненных операций была получена обученная LSTM-модель. Время обучения на каждой эпохе составляло 1–16 мс, потери – $8,4742e-04$, метрика – 1,3929.

Оценка качества обученной LSTM-модели выполнялась с помощью тренировочной и тестовой выборки размером 2 000 и 1 000 значений соответственно. После обучения сети она оценивается с использованием тестовых данных. В качестве входных данных для сети во время оценки должны быть предоставлены только данные для текущего временного шага. Затем сеть прогнозирует значения для следующего временного шага. Цель состоит в том, чтобы свести к минимуму среднеквадратическую ошибку между прогнозируемыми значениями и фактическими наблюдениями на следующем временном шаге. Меньшее значение среднеквадратического отклонения указывает на более высокую точность прогноза, что означает более точное соответствие между прогнозируемыми значениями и фактическими наблюдениями.

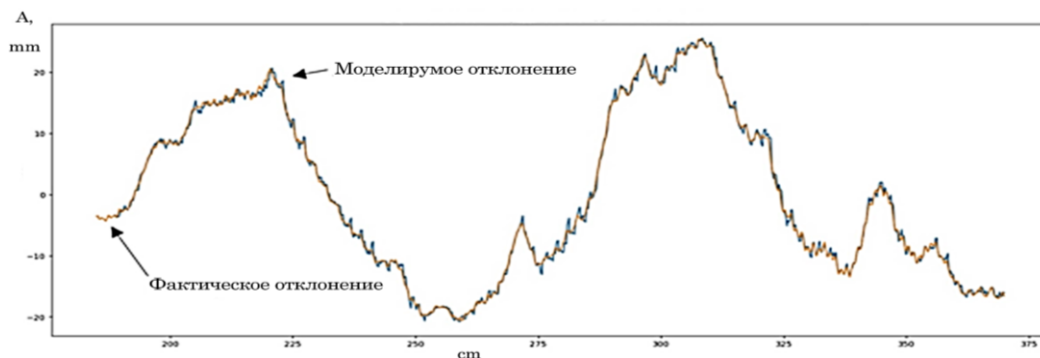


Рис. 4. Фактические и смоделированные значения горизонтальных неровностей правой рельсовой нити
Fig. 4. Actual and simulated values of horizontal unevenness of the right rail thread

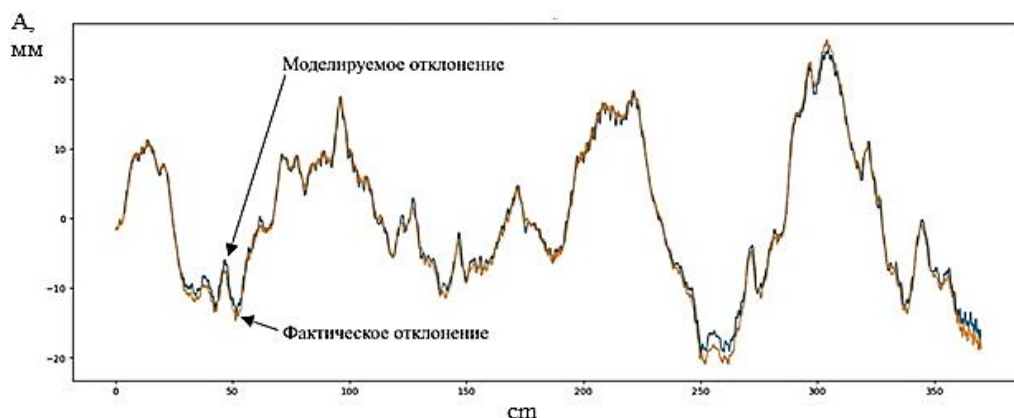


Рис. 5. Фактические и смоделированные значения вертикальных неровностей правой рельсовой нити
Fig. 5. Actual and simulated values of vertical unevenness of the right rail thread

Таблица 1. Среднеквадратичные ошибки прогнозирования LSTM-моделей для значений вертикальных неровностей

Table 1. Root Mean Square Prediction Errors of LSTM Models for Vertical Roughness Values

Глубина прогноза Depth of forecast	LSTM-модель LSTM-model	
	Левая нить Left thread	Правая нить Right thread
Прогноз на три шага Three steps forecast	0,936	0,866
Прогноз на пять шагов Five steps forecast	1,255	0,906
Прогноз на десять шагов Ten steps forecast	1,844	1,772

Таблица 2. Среднеквадратичные ошибки прогнозирования LSTM-моделей для значений горизонтальных неровностей

Table 2. Root Mean Square Prediction Errors of LSTM Models for Horizontal Roughness Values

Глубина прогноза Depth of forecast	LSTM-модель LSTM-model	
	Левая нить Left thread	Левая нить Left thread
Прогноз на три шага Three steps forecast	0,902	0,886
Прогноз на пять шагов Five steps forecast	0,962	0,906
Прогноз на десять шагов Ten steps forecast	1,845	1,772

Результаты фактических и смоделированных значений горизонтальных неровностей правой рельсовой нити для тестовой выборки приведены на рис. 4, а для вертикальных неровностей – на рис. 5.

Для определения качества LSTM-моделей неровностей были вычислены среднеквадратичные ошибки прогнозирования этих моделей для 200 последовательных значений неровностей, представленные в табл. 1 и 2.

Построенные LSTM-модели для 148, 149, 179, 181 км Октябрьской железной дороги, а также 1 024, 1 025, 1 032, 1 033, 1 034 км Горьковской железной дороги продемонстрировали свое высокое качество на всех тестовых выборках и подтвердили возможность и целесообразность их использования при моделировании геометрии рельсовой колеи.

Заключение

В статье приведены примеры сложных физических процессов, происходящих в железнодорожных системах, требующих интеграции классических подходов с методами машинного обучения. С помощью таких интегральных ме-

тодов можно оптимизировать графики технического обслуживания и обеспечивать безопасную и надежную работу железнодорожной сети, должным образом прогнозируя будущее состояние железнодорожных путей. Точное прогнозирование геометрических параметров пути важно для планирования работ по техническому обслуживанию. Раннее выявление возможных проблем позволяет своевременно проводить техническое обслуживание, избегать дорогостоящего ремонта и сводить к минимуму задержки в движении поездов.

Представленный пример LSTM-модели распознает незначительные изменения в геометрии рельсовой колеи, эффективно фиксирует тенденции и флуктуации в пределах исследуемых сегментов, успешно прогнозируя соответствующие значения профиля. Среднеквадратические ошибки показывают увеличение значения в соответствии с дальностью прогноза, это может быть обусловлено небольшим набором обучающей выборки. Основываясь на этих результатах, следующим этапом является дальнейшее усовершенствование модели для повышения производительности и достижения

более высоких показателей точности моделирования геометрии рельсовой колеи, а также разработка других моделей с помощью нейронных сетей различных архитектур и алгоритмов для сравнения результатов моделирования и точного определения более эффективных моделей применительно к задачам моделирования геометрии рельсовой колеи.

Список литературы

1. Спектральный состав неровностей пути и напряженно-деформированное состояние его элементов / А.Я. Коган, М.А. Левинзон, С.В. Малинский и др. // Вестник ВНИИЖТ. 1991. № 1. С. 39–43.
2. Сивицкий Д.А. Анализ опыта перспектив применения искусственных нейронных сетей на железнодорожном транспорте // Вестн. Сибир. гос. ун-та путей сообщ. 2021. № 2 (57). С. 33–41.
3. Каменский Д.А. Применение моделей векторной авторегрессии при прогнозировании в финансах и экономике // Фундаментальные исследования. 2019. № 5. С. 45–49.
4. Vector Autoregression (VAR) for Multivariate Time Series // geeksforgeeks : site. URL : https://translated.turbopages.org/proxy_u/en-ru.ru.90520b89-66978ac7-0d872144-74722d776562/ <https://www.geeksforgeeks.org/vector-autoregression-var-for-multivariate-time-series/> (Accessed March 25, 2024).
5. Хайкин С. Нейронные сети : полный курс. М. : Вильямс, 2006. 1104 с.
6. Пилецкая А.В. Искусственная нейронная сеть и ее применение при диагностике железнодорожных путей // Молодой ученый. 2020. № 20 (310). С. 48–50.
7. Deep convolutional neural networks for detection of rail surface defects / S. Faghih-Roohi, S. Hajizadeh, A. Núñez et al. // International joint conference on neural networks (IJCNN). Vancouver, 2016. P. 2584–2589. DOI: 10.1109/IJCNN.2016.7727522.
8. Денисенко М.А., Исаева А.С., Коц И.Н. Тестирование прототипа системы мониторинга состояния рельсового пути с использованием LSTM рекуррентных нейронных сетей // Науч.-техн. ведомости Санкт-Петербург. гос. политехн. ун-та. Физико-математ. науки. 2022. Т. 15. № S3.2. С. 51–55.
9. Сорокин Д.В., Кравец А.С. Теоретические предпосылки использования нейронных сетей для решения эксплуатационных задач на железнодорожном транспорте // Транспорт: наука, образование, производство : сб. науч. тр. Ростов н/Д, 2019. Т. 1. С. 214–218.
10. Незевак В.Л. Совершенствование модели влияния параметров графика движения поездов на тяговое электропотребление на участках постоянного и переменного тока с I и II типом профиля пути при помощи регрессионных моделей и нейронных сетей // Вестник транспорта Поволжья. 2017. № 6 (66). С. 34–44.
11. Анализ результатов работы и оценка эффективности гибридной модели идентификации подвижных единиц железнодорожного транспорта / Д.С. Гвоздев, М.Д. Линденбаум, В.В. Храмов и др. // Вестн. Ростов. гос. ун-та путей сообщ. 2013. № 4 (52). С. 47–54.
12. Railway passenger traffic volume prediction based on neural network / W. Zhuo, J. Li-Min, Q. Yong et al. // Applied Artificial Intelligence. 2007. Vol. 21. Iss. 1. P. 1–10. DOI: <https://doi.org/10.1080/08839510600938409>.
13. Railway freight volume forecasting of neural network based on economic cycles / Y.-H. Guo, Z.-Y. Chen, F.-L. Feng et al. // Tiedao Xuebao. 2010. Vol. 32, Iss. 5. P. 1–6.
14. Рекуррентная нейронная сеть (RNN): виды, обучение, примеры // Neurohive : сайт. URL: <https://neurohive.io/ru/osnovy-data-science/rekurrentnye-nejronnye-seti/> (Дата обращения 14.03.2024).
15. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. 1997. Vol. 9. Iss. 8. P. 1735–1780. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>.
16. Ahmed M. Predicting track geometry using machine-learning methods : master's theses. Newark, 2023. 134 p.
17. ADF тест для анализа временных рядов // Русские Блоги : сайт. URL : <https://russianblogs.com/article/4449640394/> (Дата обращения 30.03.2024).
18. Решение проблем с последовательностью с помощью LSTM в Keras // Rukovodstvo : сайт. URL : https://rukovodstvo.net/posts/id_976/ (Дата обращения 05.04.2024).

References

1. Kogan A.Ya., Levinzon M.A., Malinskii S.V., Pevzner V.O. Spektral'nyi sostav nerovnostej puti i napryazhenno-deformirovannoe sostoyanie ego elementov [The spectral composition of the path irregularities and the stress-strain state of its elements]. *Vestnik VNIIZhT* [Bulletin of the All-Union Scientific and Research Institute of Railway Transport], 1991, no. 1, pp. 39–43.
2. Sivitskii D.A. Analiz opyta perspektiv primeneniya iskusstvennykh neironnykh setei na zheleznodorozhnom transporte [Analysis of the experience of prospects for the use of artificial neural networks in railway transport]. *Vestnik Sibirskogo gosudarstvennogo universiteta putei soobshcheniya* [Bulletin of the Siberian State Transport University], 2021, no. 2 (57), pp. 33–41.
3. Kamenskii D.A. Primenenie modelei vektornoj avtoregressii pri prognozirovanii v finansakh i ekonomike [Application of vector autoregression models in forecasting in finance and economics]. *Fundamental'nye issledovaniya* [Basic research], 2019, no. 5, pp. 45–49.
4. Vector Autoregression (VAR) for Multivariate Time Series (Electronic Resource). Available at: https://translated.turbopages.org/proxy_u/en-ru.ru.90520b89-66978ac7-0d872144-74722d776562/ <https://www.geeksforgeeks.org/vector-autoregression-var-for-multivariate-time-series/> (Accessed March 25, 2024)
5. Haikin S. Neironnye seti: polnyi kurs [Neural networks: a comprehensive Foundation]. Moscow: Williams Publ., 2006. 1104 p.

6. Piletskaya A.V. Iskusstvennaya neironnaya set' i ee primeneniye pri diagnostike zheleznodorozhnykh putei [Artificial neural network and its application in railway diagnostics]. *Molodoi uchenyi* [Young scientist], 2020, no. 20 (310), pp. 48–50.
7. Faghieh-Roohi S., Hajizadeh S., Núñez A., Babuska R., De Schutter B. Deep Convolutional Neural Networks for Detection of Rail Surface Defects. *International joint conference on neural networks (IJCNN)*. Vancouver, 2016, pp. 2584–2589. DOI: 10.1109/IJCNN.2016.7727522.
8. Isaeva A.S., Denisenko M.A., Kots I.N. Testirovaniye prototipa sistemy monitoringa sostoyaniya rel'sovogo puti s ispol'zovaniem LSTM rekurrentnykh neironnykh setei [Testing a prototype of a track condition monitoring system using LSTM recurrent neural networks]. *Nauchno-tekhnicheskie vedomosti Sankt-peterburgskogo gosudarstvennogo politekhnicheskogo universiteta. Fiziko-matematicheskie nauki* [Scientific and Technical Bulletin of Saint Petersburg State Polytechnic University. Physical and Mathematical Sciences], 2022, vol. 15, no. 3.2, pp. 51–55.
9. Sorokin D.V., Kravets A.S. Teoreticheskie predposylki ispol'zovaniya neironnykh setei dlya resheniya ekspluatatsionnykh zadach na zheleznodorozhnom transporte [Theoretical prerequisites for the use of neural networks to solve operational problems in railway transportation]. *Sbornik nauchnykh trudov «Transport: nauka, obrazovanie, proizvodstvo»* [Proceedings «Transport: science, education, production»]. Rostov on Don, 2019, vol. 1, pp. 214–218.
10. Nezevak V.L. Sovershenstvovaniye modeli vliyaniya parametrov grafika dvizheniya poezdov na tyagovoye elektropotrebleniye na uchastkakh postoyannogo i peremennogo toka c I i II tipom profilya puti pri pomoshchi regressionnykh modelej i neironnykh setei [Improving the model of the influence of train schedule parameters on traction power consumption in sections of constant and alternating current with type I and II of the track profile using regression models and neural networks]. *Vestnik transporta Povolzh'ya* [Bulletin of transport of the Volga region], 2017, no. 6 (66), pp. 34–44.
11. Gvozdev D.S., Lindenbaum M.D., Khramov V.V., Kovalev S.M. Analiz rezul'tatov raboty i otsenka effektivnosti gibridnoi modeli identifikatsii podvizhnykh edinit zheleznodorozhnogo transporta [Analysis of the results of the work and evaluation of the effectiveness of the hybrid model of identification of mobile units of railway transport]. *Vestnik Rostovskogo gosudarstvennogo universiteta putei soobshcheniya* [Bulletin of the Rosotov State Transport University], 2013, no. 4 (52), pp. 47–54.
12. Zhuo W., Li-Min J., Yong Q., Yan-Hui W. Railway passenger traffic volume prediction based on neural network. *Applied Artificial Intelligence*, 2007, vol. 21, iss. 1, pp. 1–10. DOI: <https://doi.org/10.1080/08839510600938409>.
13. Guo Y.-H., Chen Z.-Y., Feng F.-L., Chang B. Railway freight volume forecasting of neural network based on economic cycles. *Tiedao Xuebao*, 2010, vol. 32, iss. 5, pp. 1–6.
14. Rekurrentnaya neironnaya set' (RNN): vidy, obuchenie, primery (Elektronnyi resurs) [Recurrent Neural Network (RNN): types, training, examples (Electronic Resource)]. Available at: <https://neurohive.io/ru/osnovy-data-science/rekurrentnye-nejronnye-seti/> (Accessed March 14, 2024).
15. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*, 1997, vol. 9, iss. 8, pp. 1735–1780. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>.
16. Ahmed M. Predicting track geometry using machine-learning methods : master's theses. Newark, 2023. 134 p.
17. ADF test dlya analiza vremennykh ryadov (Elektronnyi resurs) [ADF test for time series analysis (Electronic resource)]. Available at: <https://russianblogs.com/article/4449640394/> (Accessed March 30, 2024)
18. Resheniye problem s posledovatel'nost'yu s pomoshch'yu LSTM v Keras (Elektronnyi resurs) [Solving sequence problems with LSTM in Keras (Electronic resource)]. Available at: https://rukovodstvo.net/posts/id_976/ (Accessed April 5, 2024).

Информация об авторах

Шарова Валерия Олеговна, ведущий инженер отдела проблем эксплуатации и предиктивной аналитики путевой инфраструктуры (пути), Научный центр «Инфраструктура», Научно-исследовательский институт железнодорожного транспорта (ВНИИЖТ), г. Москва; e-mail: sharova.valeriia@vniizht.ru.

Information about the authors

Valeriya O. Sharova, Lead Engineer of the Department of Operational Problems and Predictive Analytics of Track Infrastructure (tracks), Scientific Center «Infrastructure», Scientific Research Institute of Railway Transport (VNIIZHT), Moscow; e-mail: sharova.valeriia@vniizht.ru.