

УДК 004.891
DOI 10.17513/snt.39978

ПРОГНОЗИРОВАНИЕ РАБОЧЕГО СОСТОЯНИЯ ЭЛЕКТРОМОБИЛЬНОЙ ЗАРЯДНОЙ СТАНЦИИ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Триандофилиди И., Коцюба И.Ю.

ФГАОУ ВО «Санкт-Петербургский национальный исследовательский университет ИТМО»,
Санкт-Петербург, e-mail: ioanis.tr@mail.ru

Аннотация. В данной статье решается задача прогнозирования состояния загруженности зарядной станции в течение определенного промежутка времени. Прогнозируемые данные дадут возможность планировать время зарядки, выбирать для конкретного рассматриваемого автомобиля наиболее выгодную и удобную зарядную станцию, что приведет к сокращению времени и улучшению качества получаемой услуги, уменьшению очередей и заторов на зарядных станциях, снижению нагрузки на электрические и транспортные системы. В ходе исследования был проведен анализ данных на основании датасета о сеансах зарядки электромобилей г. Данди, описаны признаки, влияющие на длительность зарядки электромобиля. Предлагаемая модель прогнозирования состоит из комбинированной рекуррентной нейронной сети LSTM и нейронной сети прямого распространения. Сравнение результатов эффективности работы предлагаемой модели, по метрикам качества Accuracy и F1score, с аналогичными существующими разработками показывают эффективность и обоснованность применения предлагаемого метода прогнозирования. Ввиду общих физических законов функционирования транспортной и электрической систем, а также универсальности зарядных устройств, результаты сравнения рассматриваемой в данной статье модели с аналогичными работами будут актуальны при использовании аналогичных датасетов.

Ключевые слова: электромобиль, транспортная система, загруженность зарядной станции, прогнозирование, LSTM нейросети

PREDICTION THE OPERATING STATE OF AN ELECTRIC VEHICLE CHARGING STATION USING NEURAL NETWORKS

Triandofilidi I., Kotsyuba I.Yu.

Saint Petersburg National Research University ITMO, Saint Petersburg, e-mail: ioanis.tr@mail.ru

Annotation. This article solves the problem of predicting the occupancy state of a charging station over a certain period of time. The predicted data will make it possible to plan charging times, select the most profitable and convenient charging station for the specific vehicle in question, which in turn will lead to a reduction in time and an improvement in the quality of the service received, a reduction in queues and congestion at charging stations, and a reduction in the load on electrical and transport systems. During the study, data analysis was carried out based on a dataset of charging sessions for electric vehicles in the city of Dundee, and characteristics affecting the charging time of an electric vehicle were described. The proposed forecasting model consists of a combined LSTM recurrent neural network and a feedforward neural network. Comparison of the performance results of the proposed model, according to the Accuracy and F1score quality metrics, with similar existing developments shows the effectiveness and validity of the proposed forecasting method. In view of the general physical laws of the functioning of transport and electrical systems, as well as the universality of chargers, the results of comparing the model discussed in this article with similar works will be relevant when using similar datasets.

Keywords: electric car, transport system, charging station load, forecasting, LSTM neural networks

Электромобили являются современным, экологически чистым и перспективным видом транспорта. Но, несмотря на интенсивное развитие технологий и инфраструктуры в электротранспортной отрасли, по-прежнему существует проблема внедрения зарядных станций, в первую очередь из-за высоких инвестиционных затрат [1]. По мере увеличения количества электромобилей на дорогах все чаще возникает ситуация, когда владелец электромобиля, чтобы зарядить машину, вынужден простоять в очереди. Особые трудности испытывают организации, эксплуатирующие электромобили постоянно, поскольку существенно возрастает необходимость

в зарядке электромашины (иногда несколько раз в день) [2]. Существующие электрозаправочные компании, такие как ChargePoint [3] или ZEVS [4], предоставляют информацию о доступности зарядной станции в режиме реального времени, однако предварительное бронирование на общественных зарядных станциях по-прежнему недоступно. Одно из решений снижения потребности электромобилей в большем количестве зарядных станций, это более эффективная загрузка уже существующих зарядных станций.

Целью данной работы являлось создание прогнозирования рабочего состояния зарядной станции в течение определенно-

го промежутка времени с момента начала зарядки электромобиля для возможности транспортным предприятиям принимать более качественные решения о выборе зарядной станции для зарядки электротранспорта, что будет способствовать оптимизации процесса перевозки, сокращению стоимости и времени доставки грузов.

Рассмотренная в статье модель представляет собой смешанную нейронную сеть [5], состоящую из рекуррентной нейронной сети (долгая краткосрочная память LSTM) [6] и нейронной сети прямого распространения.

Задачи исследования:

- Анализ данных на основании датасета о сеансах зарядки электромобилей г. Данди, Великобритания [7]. Описание признаков, влияющих на длительность зарядки электромобиля.

- Построение усовершенствованной гибридной модели, учитывающей дополнительные признаки, а именно: уровень заряда в начальный момент времени, тип зарядного устройства, введен коэффициент, характеризующий загруженность зарядной станции в определенный момент времени.

- Сравнить эффективности работы полученной модели с ранее перечисленными моделями.

Материалы и методы исследования

Анализ и обработка данных

Рассматриваемый в работе датасет представляет собой описание различных сеансов зарядки электромобилей г. Данди. Каждый сеанс характеризуется следую-

щими данными: время начала и окончания сеанса зарядки, идентификатор зарядного устройства, количество потребленной за сеанс энергии, мощность и тип зарядного устройства [5]. Ввиду невысокой загруженности медленных зарядных устройств в данном исследовании рассмотрено прогнозирование рабочего состояния быстрых зарядных устройств.

Было осуществлено наблюдение за работой 9 «быстрых» зарядных станций в промежутке времени с 5 марта 2018 г. по 4 июня 2018 г. Всего была зафиксирована 8491 зарядная сессия. На рис. 1 представлена характеристика данных сессий.

Из рис. 1 видно, что продолжительность 25% сеансов зарядки составляет не более 16 мин, продолжительность 75% сеансов зарядки составляет не более 37 мин. Половина электромобилей заряжается за 28 мин. Стоит отметить, что часто встречаются случаи длительности зарядки от 60 до 127 мин.

Профиль загруженности зарядной станции. Загруженность зарядной станции характеризуется профилем нагрузки зарядной станции. На рис. 2 показано распределение времени подключения электромобилей в будние и выходные дни. Видно, что в будние дни большинство сеансов зарядки происходят с 8:00 до 23:00 (между 480 и 1380 минутой суток), с пиком между 10:00 и 17:00 (между 600 и 1020 минутой суток). В выходные дни профиль нагрузки зарядных станций более плавный. В данной модели используется коэффициент загрузки станции, который характеризует загруженность зарядной станции в конкретный десятиминутный промежуток времени суток.




Рис. 1. Длительность сеансов зарядки
Источник: составлено авторами

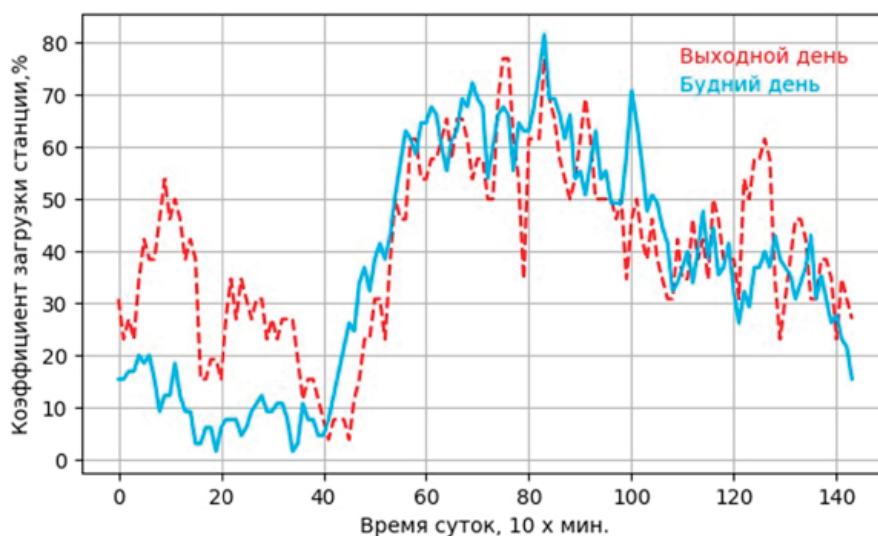


Рис. 2. Профиль нагрузки зарядной станции
 Источник: составлено авторами

Таблица 1

Признаки, используемые в модели

Признак (переменная)	Значение
Время суток (t)	Сутки разделены на 144 временных промежутка. Время суток является одним из 144 значений. $t \in \{1, 2, 3...144\}$
День недели (d)	Понедельник: $d = 0, \dots$, Воскресенье: $d = 6$
Будний день / выходной день (w)	Будний день: $w = 0$ /выходной день: $w = 1$
Тип зарядного устройства	APT Triple Rapid Charger: $tp = 1$, APT Dual Rapid Charge: $tp = 2$, APT 50kW Raption: $tp = 3$
Уровень заряда батареи	Q, уровень заряда батареи электромобиля в момент начала зарядки
Коэффициент средней загруженности зарядной станции	Коэффициент характеризует загруженность зарядной станции в конкретный десятиминутный промежуток времени суток. Различают коэффициенты для буднего дня и для выходного дня
Временная последовательность, характеризующая рабочее состояние зарядной станции	Временная последовательность $\{t-1, t-2, t-3, \dots, t-k\}$, описывающая состояние зарядной станции k временных промежутков назад. $t-k = 1$ – зарядная станция эксплуатируется. $t-k = 0$ – зарядная станция находится в простое.

В данном исследовании рассмотрены «быстрые» зарядные станции трех типов: APT Triple Rapid Charger (1), APT Dual Rapid Charge (2), APT 50kW Raption (3). Особенностью процесса зарядки батареи электромобиля является то, что по мере увеличения уровня заряда батареи интенсивность процесса зарядки снижается. Данные виды зарядных станций характеризуются мощностью и кусочно-линейным профилем зарядки электромобиля.

С учетом описания вышеперечисленных параметров электромобиля и зарядной станции в табл. 1 был сформирован перечень признаков, используемых в качестве входных данных проектируемой модели.

Модель прогнозирования состояния работы зарядной станции

Длительность работы зарядной станции зависит от многих факторов: времени суток, дня недели, мощности зарядного устройства, уровня заряда батареи в момент начала зарядки, цены получаемой услуги, географического расположения зарядной станции. Ввиду ограниченности используемых данных, в данном исследовании используются следующие признаки: время суток, день недели, тип зарядного устройства, уровень заряда батареи в момент начала зарядки. Время в модели представлено интервально, один час разделен на 6 промежут-

ков по 10 мин. Датасет поделен на обучающую и тестовую выборку, в соотношении 70 и 30% соответственно [5]. Для выполнения данной задачи предлагается комбинированная нейронная сеть, которая состоит из LSTM ячеек и нейронной сети прямого распространения. Предлагаемая модель, на основании свойства автокорреляции состояния зарядной станции, учитывает краткосрочную составляющую возможности работы зарядной станции. Кратковременная составляющая прогноза моделируется LSTM блоком. В свою очередь, на основании таких признаков, как время суток, день недели, тип зарядного устройства, уровень заряда батареи в момент начала зарядки, учитывается долгосрочная составляющая возможности работы зарядной станции,

описываемая многослойным персептроном. Архитектура предлагаемой модели представлена на рис. 3. Гиперпараметры модели приведены в табл. 2.

В качестве функции потерь данной модели, для измерения разницы между прогнозируемыми и наблюдаемыми результатами, применяется средняя абсолютная ошибка (mean absolute error (MAE)):

$$MAE = \frac{1}{k} \sum_{s=t}^{t+k-1} |\hat{y}_s - y_s|,$$

где \hat{y}_s – прогнозируемое значение состояния работы зарядной станции в момент времени s ; y_s – реальное значение состояния работы зарядной станции в момент времени s ; k – длина прогнозируемого промежутка времени.

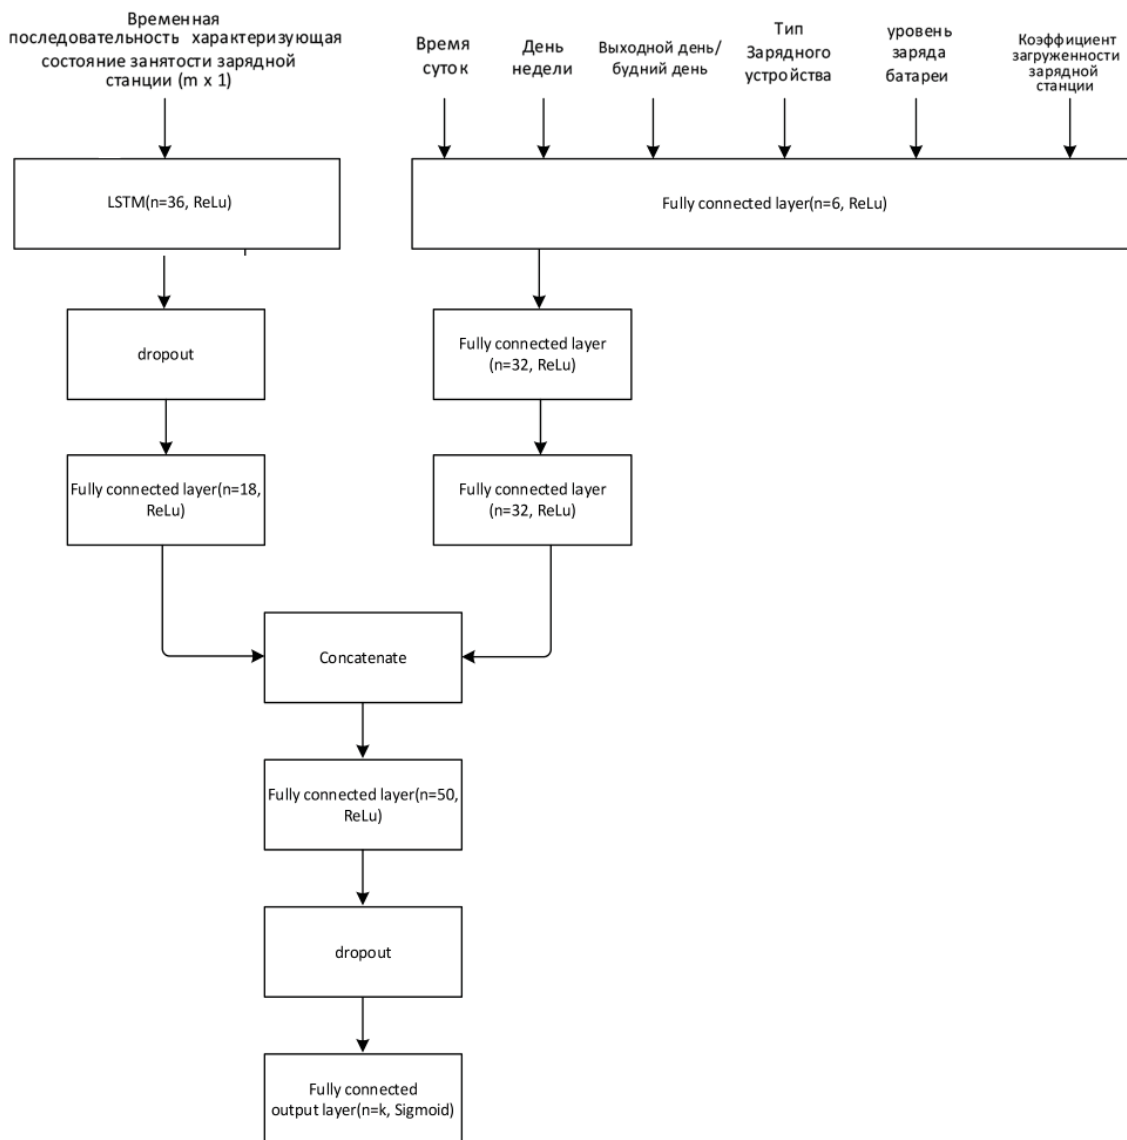


Рис. 3. Архитектура модели прогнозирования состояния работы зарядной станции
Источник: составлено авторами

Таблица 2

Гиперпараметры модели

Гиперпараметр	Значение
Регуляризация	Dropout (0.2)
Размер Mini-batch	30
Количество эпох	15
Оптимизатор	Adam

Таблица 3

Сравнение показателя «Accuracy» между моделями

Accuracy						
k-step ahead	1	3	6	12	24	36
Logistics	0,8837	0,8034	0,7518	0,7166	0,6927	0,6809
SVM	0,7511	0,7421	0,7366	0,7328	0,7295	0,7283
Random forest	0,8370	0,7710	0,7397	0,7240	0,7162	0,7137
Adaboost	0,8816	0,8042	0,7563	0,7257	0,7080	0,6999
Hybrid LSTM	0,9999	0,8926	0,8187	0,7776	0,7593	0,7511
Upgraded model	0,9999	0,9421	0,8326	0,7909	0,7636	0,7458

Таблица 4

Сравнение показателя «F1 score» между моделями

F1 score						
k-step ahead	1	3	6	12	24	36
Logistics	0,7760	0,7754	0,6687	0,5423	0,4110	0,3367
SVM	0,5987	0,6805	0,6031	0,5003	0,3918	0,3330
Random forest	0,6860	0,7247	0,6359	0,5452	0,4566	0,4088
Adaboost	0,7681	0,7736	0,6676	0,5425	0,4118	0,3366
Hybrid LSTM	0,9999	0,8562	0,7305	0,6108	0,4896	0,4279
Upgraded model	0,9999	0,9213	0,7501	0,6451	0,5182	0,4413

Большую часть времени зарядные станции находятся в нерабочем состоянии. Рассматриваемые данные являются несбалансированными. Вследствие чего вводится дополнительный показатель качества работы модели – F1score.

$$F1_{score} = \frac{2}{precision^{-1} + recall^{-1}} = \frac{2TP}{TP + FN + FP}$$

где *TP* – истинноположительное решение; *FP* – ложноположительное решение; *FN* – ложноотрицательное решение [6].

Результаты исследования и их обсуждение

Результаты многошагового прогнозирования состояния зарядной станции усовер-

шенствованной модели и аналогичных моделей [5] представлены в табл. 3 и 4. Длина временного окна прогнозирования изменяется от 1 (10 мин) до 36 (6 ч). Предлагаемая усовершенствованная модель превосходит по качеству прогнозирования аналогичные модели. Точность прогнозирования снижается по мере увеличения длины временного окна прогнозирования. Начиная с 12 шагов (120 мин), показатели эффективности модели существенно снижаются. Исходя из вышеуказанного, модель целесообразно использовать для прогнозирования во временном диапазоне, не превышающем 60 мин.

Заключение

В данной работе был предложен метод прогнозирования состояния загруженно-

сти зарядной станции с помощью гибридной нейронной сети специального типа. В процессе исследования было проведено сравнение рассматриваемого метода с аналогичными моделями, решающими задачу прогнозирования состояния зарядной станции. Во всех случаях по таким показателям, как «Assigasy» и «F1 score», предложенная модель показала более высокую эффективность. Результаты статьи могут быть использованы в практических целях для последующих разработок систем управления и планирования процесса зарядки электромобилей транспортными предприятиями.

Список литературы

1. ООН. Экономический и Социальный Совет. Оценка новых тенденций в области инфраструктуры для зарядки электромобилей. [Электронный ресурс]. URL: https://unesco.org/sites/default/files/2022-12/ECE_TRANS_2023_23R.pdf (дата обращения: 12.02.2024).
2. Haoming Liu, Wenqian Yin, Xiaoling Yuan and Man Niu. Reserving Charging Decision-Making Model and Route Plan for Electric Vehicles Considering Information of Traffic and Charging Station // *Sustainability*. 2018. Vol. 10 (5). P. 1324.
3. Компания электротранспортной инфраструктуры, ChargePoint Driver Portal. [Электронный ресурс]. URL: <https://driver.chargepoint.com> (дата обращения: 10.02.2024).
4. Компания электротранспортной инфраструктуры, ZEVS. [Электронный ресурс]. URL: <https://zevs.group.com>. (дата обращения: 11.03.2024).
5. Tai-Yu Ma, Sébastien Faye. Multistep Electric Vehicle Charging Station Occupancy Prediction using Hybrid LSTM Neural Networks // *Energy*. 2022. Vol. 244. Part B. [Электронный ресурс]. URL: <https://arxiv.org/ftp/arxiv/papers/2106/2106.04986.pdf> (дата обращения: 16.02.2024).
6. Сай В.К., Щербаков М.В. Прогнозирование отказов сложных многообъектных систем на основе комбинации нейросетей: пути повышения точности прогнозирования // *Прикаспийский журнал: управление и высокие технологии*. 2020. № 1 (49). С. 49–60.
7. Центр открытых данных города Данди, Великобритания. [Электронный ресурс]. URL: <https://data.dundecity.gov.uk> (дата обращения: 13.03.2024).