

## ТЕХНИЧЕСКИЕ НАУКИ



УДК 656.13

### Прогнозирование транспортных потоков на основе сетевых моделей с долгой краткосрочной памятью

А.А. Феофилова, Цзян Цзисяо

Донской государственный технический университет, г. Ростов-на-Дону, Российская Федерация

#### Аннотация

Для повышения эффективности дорожного движения и реализации эффективного управления транспортными потоками необходимо выполнять прогнозирование их состояния. Одной из ключевых задач в данной области является разработка моделей, которые способны точно учитывать динамические изменения в транспортных потоках и предсказывать их характеристики в предстоящие периоды. С целью повышения точности прогнозирования, используется модель, основанная на нейронных сетях с долгой краткосрочной памятью (LSTM). Цель работы — предложить модель LSTM для повышения эффективности и точности прогнозирования транспортных потоков

**Ключевые слова:** краткосрочный прогноз транспортного потока, управление транспортным потоком, интеллектуальные транспортные системы, модель нейронной сети

**Для цитирования.** Феофилова А.А., Цзян Цзисяо. Прогнозирование транспортных потоков на основе сетевых моделей с долгой краткосрочной памятью. *Молодой исследователь Дона.* 2024;9(6):4–8.

### Traffic Flow Prediction Based on Long Short-Term Memory Network Models

Anastasiya A. Feofilova, Jiang Jixiao

Don State Technical University, Rostov-on-Don, Russian Federation

#### Abstract

In order to improve the efficiency of road transport and realize effective traffic flow management, it is important to predict traffic conditions. One of the main tasks in this area is the development of models that can accurately account for changes in traffic flow and predict its characteristics in the future. To increase the accuracy of forecasts, a model based on long short-term memory neural networks (LSTM) is used. The aim of this work is to propose an LSTM-based model to enhance the efficiency and accuracy of traffic flow forecasting.

**Keywords:** short-term traffic flow prediction, traffic flow management; intelligent transportation systems, neural network model

**For citation.** Feofilova AA, Jiang Jixiao. Traffic Flow Prediction Based on Long Short-Term Memory Network Models. *Young Researcher of Don.* 2024;9(6):2024;9(6):4–8.

**Введение.** В краткосрочном прогнозировании транспортных потоков традиционно используются методы статистической теории и стандартные нейросетевые алгоритмы [1–3]. Однако с развитием глубокого обучения появились эксперименты, в которых исследователи начали применять этот подход для прогнозирования временных рядов. Поскольку традиционные модели нейронных сетей имеют свои ограничения, Hochreiter и Schmidhuber предложили специализированную модель рекуррентной нейронной сети с долговременной краткосрочной памятью (LSTM). Модель LSTM способна изучать нелинейные структуры данных, эффективно извлекать ключевые особенности входных данных и обеспечивать долговременную память [4–6]. Структура модели LSTM показана на рис. 1.

Краткосрочное прогнозирование транспортного потока включает краткосрочное прогнозирование интенсивности, скорости, плотности и является основной частью интеллектуальной транспортной системы [7, 8]. По сравнению со среднесрочным и долгосрочным прогнозированием транспортного спроса, в задачах транспорт-

ного планирования, где временной интервал часто составляет часы, дни, месяцы или даже годы [9, 10], краткосрочные прогнозы транспортных потоков более целенаправленно выявляют микроскопические изменения транспортных потоков, а временной интервал, как правило, не превышает 30 минут. Поскольку состояния транспортного потока часто колеблются под воздействием таких факторов, как случайные или особые события, погода и случайное поведение водителей, то в краткосрочной перспективе отмечается его большая нелинейность и сложность, чем в долгосрочной перспективе.

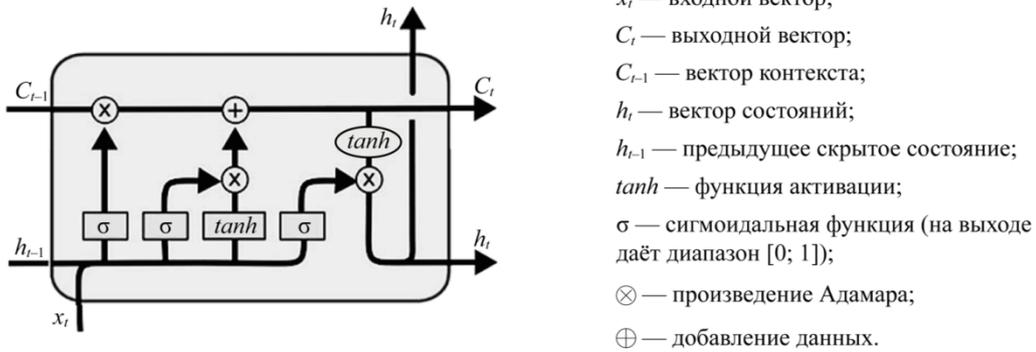


Рис. 1. Структура модели нейронной сети LSTM [9]

Цель работы — на основе предыдущих исследований в области управления дорожным движением предложить модель LSTM для повышения эффективности и точности прогнозирования транспортных потоков.

**Основная часть.** Основной моделью прогнозирования в данной работе является нейронная сеть LSTM. Выражение выглядит следующим образом:

$$Y(t) = w \times L(t) + 1 - w \times G(t), \quad (1)$$

где  $Y(t)$  и  $G(t)$  — предсказанные значения модели LSTM;  $L(t)$  — функция активации;  $w$  — интегрированный вес.

В качестве данных для экспериментов используются данные о дорожном движении, содержащие сведения об идентификации детектора, интенсивности дорожного движения и занятости детектора, и полученные из открытых источников UTD19 [11] в городе Турине с 26 сентября по 30 сентября 2024 г., а интервал детектирования составляет 5 минут. Данные о транспортном потоке сначала подвергаются нормализации, а затем очистке и фильтрации для адаптации их к модели LSTM. Обработанные данные о транспортных потоках показаны на рис. 2.

После процедуры нормализации данные о транспортных потоках, собранные с 26 по 30 сентября, вводятся в модель LSTM. На рис. 3 показана часть кода для обучения модели LSTM в MATLAB. По завершении обучения модели становится возможным осуществление прогнозов транспортных потоков.

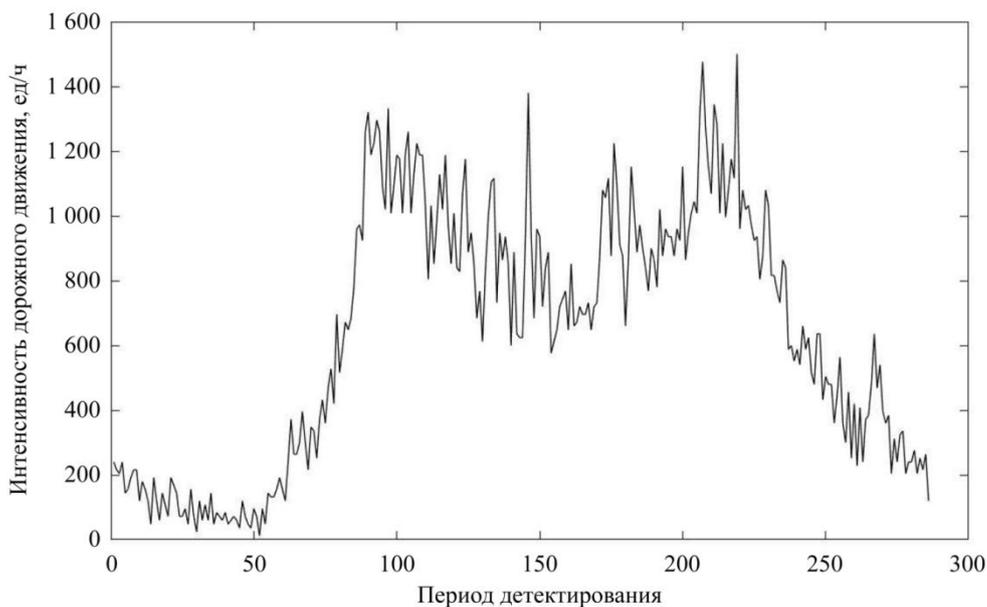


Рис. 2. Обработка данных о транспортных потоках

```

%% Clear environment variables
warning off           % Close the alarm message
close all            % Close the open window
clear                % Clear the variable
clc                  % Clear the command line

%% Import data (single column of time series data)
result = xlsread('11223.xlsx');

%% Data analysis
num_samples = length(result); % Number of samples
kim = 15;          % Delay step (kim historical data as independent variables)
zim = 1;           % Forecast across zim time points
    
```

Рис. 3. Частичный код модели LSTM в сочетании с машинным обучением

**Описание проблемы.** Для оценки точности предсказанных значений авторами статьи были использованы исходные данные о транспортном потоке, зафиксированные 27 сентября. Затем эти данные были сопоставлены с предсказанными значениями, полученными с помощью модели LSTM. Результаты сравнения представлены на рис. 4.

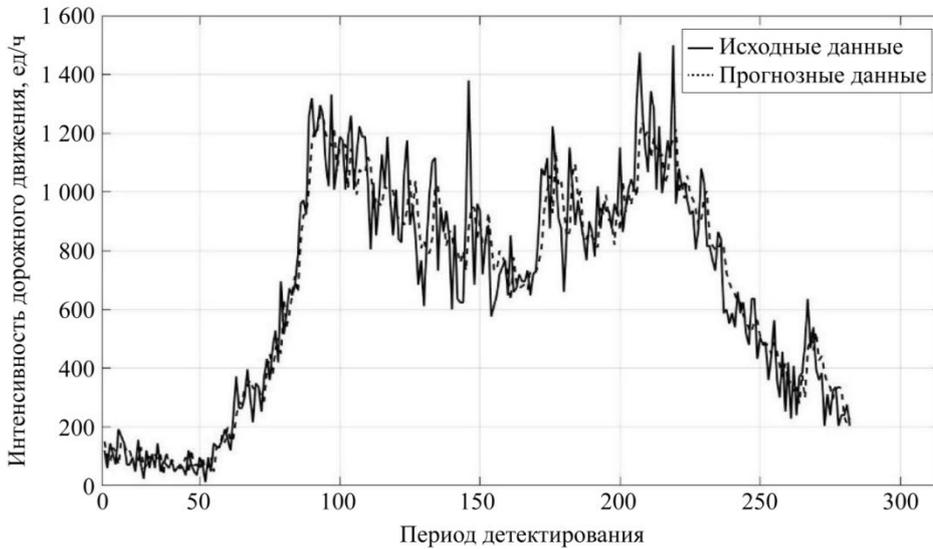
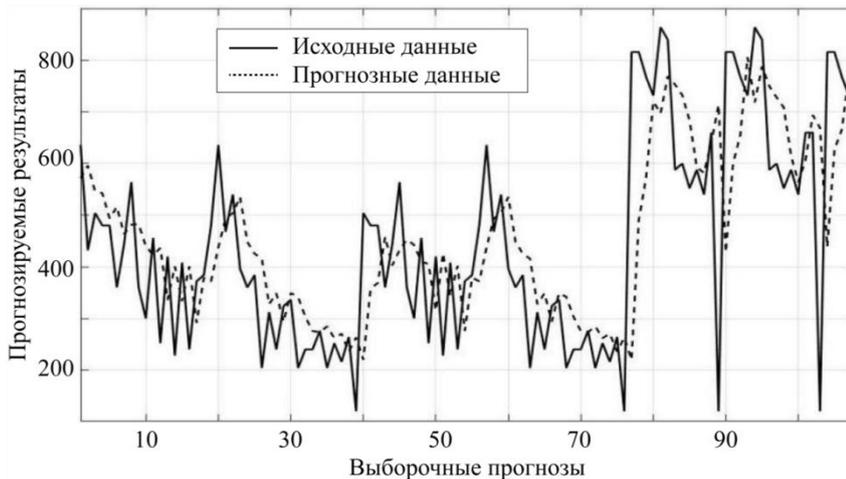
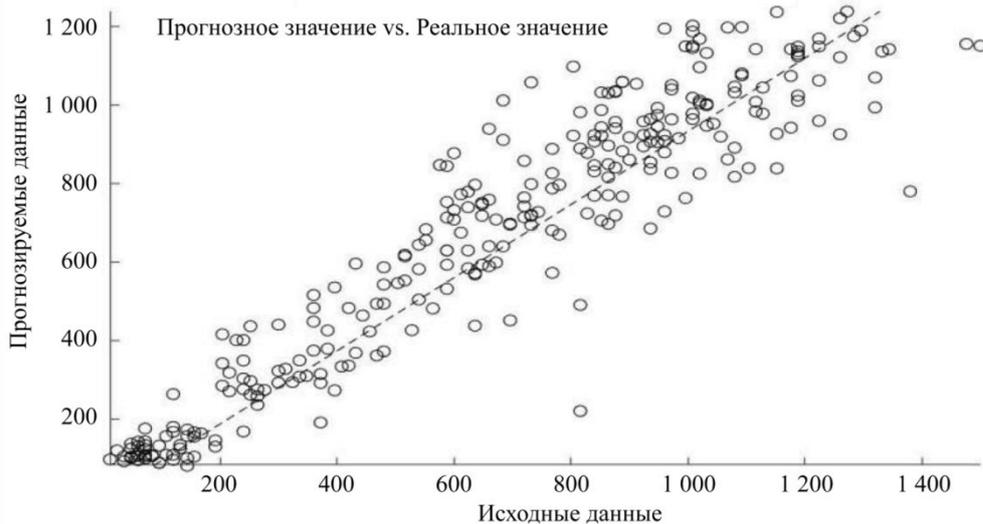


Рис. 4. Сравнение исходных и прогнозируемых значений

Черная сплошная линия представляет исходные данные о транспортном потоке, а черная пунктирная линия — предсказанные данные о транспортном потоке. Из рис. 5 видно, что предсказанные значения хорошо согласуются с исходными значениями, что свидетельствует о высоком уровне соответствия между двумя представленными кривыми, а следовательно — об адекватности применения модели LSTM.



a)



б)

Рис.5. График сравнения прогнозируемых и исходных значений:  
а — сравнение точности прогноза данных; б — эффект подгонки

Для обеспечения точности результатов прогнозирования необходимо ввести в LSTM-модель данные о транспортном потоке с 28 по 30 сентября, а затем проверить прогнозируемые данные о транспортном потоке путем оценки среднеквадратичной ошибки и коэффициента корреляции. Значения оценки были получены в MATLAB. В таблице 1 приведены результаты оценки.

Таблица 1

Результаты оценки адекватности применяемой модели

Показатели оценки				
Дата	Объем данных	$R^2$	RMSE	Коэффициент корреляции ( $\rho$ )
27 сентября	288	0,8817	133,3843	0,827
28 сентября	288	0,9011	142,1873	0,838
29 сентября	288	0,8379	138,3471	0,925
30 сентября	288	0,8527	140,2530	0,903

В таблице представлены значения коэффициента корреляции ( $\rho$ ) и среднеквадратичной ошибки  $R^2$  для исходных и прогнозируемых данных. Коэффициент корреляции отражает степень взаимосвязи между фактическими и прогнозируемыми значениями, при этом его значение колеблется в диапазоне от  $-1$  до  $+1$ . Чем ближе значение коэффициента корреляции к  $1$ , тем более выраженной является линейная корреляция между двумя наборами данных. Анализ данных таблицы 1 показывает, что коэффициент корреляции варьируется от  $0,8$  до  $0,9$ , что свидетельствует о высокой степени связи между исходными и прогнозируемыми данными. Более того, все значения  $R^2$  превышают  $0,80$ , что также указывает на хорошую корреляцию между прогнозируемыми и фактическими данными.

**Заключение.** В этой статье модель LSTM впервые используется для краткосрочного прогнозирования характеристик транспортного потока в сочетании с машинным обучением в MATLAB. Усовершенствованный автором программный код модели демонстрирует значительное превосходство в области краткосрочного прогнозирования транспортных потоков, что подчеркивает важность применения современных вычислительных технологий для решения задач в области динамического управления транспортными потоками и развития интеллектуальных транспортных систем.

#### Список литературы

1. Polson NG, Sokolov VO. Deep Learning for Short-Term Traffic Flow Prediction. *Transportation Research Part C: Emerging Technologies*. 2017;79:1–17. <https://doi.org/10.1016/j.trc.2017.02.024>
2. Bharti, Poonam Redhu, Kranti Kumar. Short-Term Traffic Flow Prediction Based on Optimized Deep Learning Neural Network: PSO-Bi-LSTM. *Physica A: Statistical Mechanics and its Applications*. 2023;625:1;29001. <https://doi.org/10.1016/j.physa.2023.129001>

3. He Yan, Tian'an Zhang, Yong Qi, Dong-Jun Yu. Short-Term Traffic Flow Prediction Based on a Hybrid Optimization Algorithm. *Applied Mathematical Modelling*. 2022;102:385–404. <https://doi.org/10.1016/j.apm.2021.09.040>
4. He Yan, Liyong Fu, Yong Qi, Dong-Jun Yu, Qiaolin Ye. Robust Ensemble Method for Short-Term Traffic Flow Prediction. *Future Generation Computer Systems*. 2022;133:395–410. <https://doi.org/10.1016/j.future.2022.03.034>
5. Sattarzadeh AR, Kutadinata RJ, Pathirana PN, Huynh VT. A Novel Hybrid Deep Learning Model with ARIMA Conv-LSTM Networks and Shuffle Attention Layer for Short-Term Traffic Flow Prediction. *Transportmetrica A: Transport Science*. 2023:1–23. <https://doi.org/10.1080/23249935.2023.2236724>
6. Danqing Kang, Yisheng Lv, Yuan-yuan Chen. Short-Term Traffic Flow Prediction with LSTM Recurrent Neural Network. In: *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*. Yokohama, Japan: IEEE; 2017. P. 1–6. <https://doi.org/10.1109/ITSC.2017.8317872>
7. Агафонов А.А., Юмаганов А.С., Мясников В.В. Анализ больших данных в геоинформационной задаче краткосрочного прогнозирования параметров транспортного потока на базе метода k ближайших соседей. *Компьютерная оптика*. 2018;42(6):1101-1111. <https://doi.org/10.18287/2412-6179-2018-42-6-1101-1111>
8. Агафонов А.А., Мясников В. В. Оценка и прогнозирование параметров транспортных потоков с использованием композиции методов машинного обучения и моделей прогнозирования временных рядов. *Компьютерная оптика*. 2014;38(3):539–549.
9. Аль-Свейти М. Методы машинного обучения для прогнозирования трафика в многоуровневой облачной архитектуре для сервисов автономных транспортных средств. *Труды учебных заведений связи*. 2022;8(4):89–99. <https://doi.org/10.31854/1813-324X-2022-8-4-89-99>
10. Xiaoyu Qi, Gang Mei, Jingzhi Tu, Ning Xi, Francesco Piccialli. A Deep Learning Approach for Long-Term Traffic Flow Prediction With Multifactor Fusion Using Spatiotemporal Graph Convolutional Network. *IEEE Transactions on Intelligent Transportation Systems*. 2023;24(8):8687–8700. <https://doi.org/10.1109/TITS.2022.3201879>
11. UTD19. URL: <https://utd19.ethz.ch/index.html> (дата обращения: 12.10.2024).

**Об авторах:**

**Феофилова Анастасия Александровна**, к.т.н., доцент кафедры организации перевозок и дорожного движения Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [feofilowa@mail.ru](mailto:feofilowa@mail.ru)

**Цзян Цзисяо**, аспирант кафедры организации перевозок и дорожного движения Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [3396945068@qq.com](mailto:3396945068@qq.com)

**Конфликт интересов:** авторы заявляют об отсутствии конфликта интересов.

*Все авторы прочитали и одобрили окончательный вариант рукописи.*

**About the Authors:**

**Jiang Jixiao**, Graduate Student of the Department of Transportation and Traffic Management, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, Russian Federation), [3396945068@qq.com](mailto:3396945068@qq.com)

**Anastasiya A. Feofilova**, Cand. Sci. (Eng.), Associate Professor of the Department of Transportation and Traffic Management, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, Russian Federation), [feofilowa@mail.ru](mailto:feofilowa@mail.ru)

**Conflict of interest:** the authors declare no conflict of interest.

*All authors have read and approved the final manuscript.*