

ИНФОРМАТИКА,
ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ
INFORMATION TECHNOLOGY,
COMPUTER SCIENCE AND MANAGEMENT



УДК 656.11

Оригинальное эмпирическое исследование

<https://doi.org/10.23947/2687-1653-2025-25-4-2215>

**Сравнительный анализ нейросетевой и машинной моделей
для краткосрочного прогнозирования транспортного потока
на скоростной автомагистрали Мэйгуан Шэньчжэня**



EDN: DWKVUM

И.В. Топилин ID, М. Хань ID, А.А. Феофилова ID, Н.А. Бескопыльный ID

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

ivan_top@mail.ru

Аннотация

Введение. При растущей загруженности автомагистралей эффективность интеллектуальных транспортных систем зависит от качественного краткосрочного прогнозирования потоков. Статистические методы недостаточно точно учитывают нелинейные и динамические изменения трафика. Более перспективны модель долгой краткосрочной памяти (LSTM) и метод опорных векторов (SVR). Однако они не ранжированы в плане корректности, так как нет работ по комплексному сопоставлению их адекватности для краткосрочного прогнозирования потоков. Представленное исследование восполняет этот пробел. Цель работы — сравнительный анализ точности LSTM и SVR и выбор оптимального подхода для прогнозирования транспортного потока на автомагистрали Мэйгуан Шэньчжэня.

Материалы и методы. Данные детекторов транспорта собраны в июне 2021 года на автомагистрали Мэйгуан. Использовались методы предварительной обработки данных, включая заполнение взвешенным средним и нормализацию. Для извлечения признаков применили автокорреляционный анализ, а также создание переменной взаимодействия скорости и занятости детектора. Модели обучались и тестировались на данных, полученных с детекторов с 5-минутными интервалами.

Результаты исследования. Показатели LSTM лучше на 17,86 % по среднеквадратической, на 19,82 % — по средней абсолютной и на 25,78 % — по средней абсолютной процентной ошибке. В периодах с наименьшей ошибкой прогнозирования интенсивности потока RMSE, MAE и MAPE для модели LSTM оказались меньше на 36,5 %, 34,3 % и 42,3 % соответственно. В периодах с наибольшей ошибкой RMSE, MAE и MAPE для LSTM оказались меньше на 73,2 %, 65,4 % и 64,4 % соответственно. Критерий Уилкоксона $<0,05$ подтвердил статистическую значимость различий.

Обсуждение. Лучшие прогнозные возможности LSTM обусловлены ее архитектурой, а именно комбинированием переменных взаимодействия и лаговых показателей. LSTM лучше учитывает временные зависимости потока, адаптируется к его сложным, долгосрочным динамическим изменениям и остается точной даже при значительных колебаниях. Меньшая прогнозная эффективность SVR обусловлена слабой, нелинейной аппроксимирующей способностью. При резких изменениях потока существенно увеличиваются показатели ошибок.

Заключение. При краткосрочном прогнозировании транспортного потока на скоростной автомагистрали, выбирая между нейросетевой и машинной моделью, следует предпочесть нейросетевую — например, LSTM. Результаты исследования целесообразно использовать в предиктивных стратегиях снижения заторов. Краткосрочное прогнозирование на основе LSTM может быть базой для оптимизации управления дорожным движением, снижения заторов и загрязняющих выбросов, а также для оптимизации интеллектуальных транспортных систем. Перспективное направление — разработка гибридных архитектур, интегрирующих контекстные данные (погода, инфраструктура, аварии) для улучшения прогнозов в режиме реального времени.

Ключевые слова: краткосрочное прогнозирование транспортных потоков, ошибка прогнозирования интенсивности потока, модель долгой краткосрочной памяти (LSTM), метод опорных векторов для регрессии (SVR)

Благодарности. Авторы выражают благодарность редакции и рецензентам за внимательное отношение к статье и замечания, которые позволили повысить ее качество.

Для цитирования. Топилин И.В., Хань М., Феофилова А.А., Бескопыльный Н.А. Сравнительный анализ нейросетевой и машинной моделей для краткосрочного прогнозирования транспортного потока на скоростной автомагистрали Мэйгуан Шэньчжэня. *Advanced Engineering Research (Rostov-on-Don)*. 2025;25(4):350–362. <https://doi.org/10.23947/2687-1653-2025-25-4-2215>

Original Empirical Research

Comparative Analysis of Neural Network and Machine Learning Models for Short-Term Traffic Flow Prediction on Shenzhen Expressway

Ivan V. Topilin  , Mengyi Han , Anastasia A. Feofilova , Nikita A. Beskopylny 

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

✉ ivan_top@mail.ru

Abstract

Introduction. With highway congestion increasing, the efficiency of intelligent transportation systems depends on high-quality short-term traffic prediction. Statistical methods do not adequately account for nonlinear and dynamic traffic changes. Long short-term memory (LSTM) and support vector machines (SVR) offer more promising solutions. However, they are not ranked in terms of accuracy, as there are no studies comprehensively comparing their adequacy for short-term traffic flow prediction. The proposed study fills this gap. The research objective is to compare the accuracy of LSTM and SVR, and select the optimal approach for traffic flow prediction on Shenzhen Meiguang Expressway.

Materials and Methods. Traffic detector data was collected on the Meiguan Expressway in June 2021. Data preprocessing methods were used, including weighted mean imputation and normalization. Autocorrelation analysis was used for feature extraction, along with the creation of an interaction variable between speed and detector occupancy. Models were trained and tested on data collected from detectors at 5-minute intervals.

Results. LSTM performed 17.86% better in terms of root mean square error, 19.82% better in terms of mean absolute error, and 25.78% better in terms of mean absolute percentage error. In periods with the lowest flow rate prediction error, RMSE, MAE, and MAPE for the LSTM model were 36.5%, 34.3%, and 42.3% lower, respectively. In periods with the highest error, RMSE, MAE, and MAPE for the LSTM model were 73.2%, 65.4%, and 64.4% lower, respectively. The Wilcoxon signed-rank test <0.05 confirmed the statistical significance of the differences.

Discussion. The superior predictive performance of LSTM stems from its architecture, namely, the combination of interaction variables and lag metrics. LSTM accounts better for flow time dependences, adapts to complex, long-term dynamic changes, and remains accurate even with significant fluctuations. The lower predictive performance of SVR stems from its weak, nonlinear approximation ability. Sudden flow changes increase significantly error rates.

Conclusion. When choosing between a neural network and a machine learning model for short-term traffic flow prediction on an expressway, the neural network model, such as LSTM, should be preferred. These research results can be useful in predictive strategies for reducing congestion. Short-term prediction based on LSTM can serve as a basis for optimizing traffic management, reducing congestion and pollutant emissions, and for optimizing intelligent transportation systems. A promising direction is the development of hybrid architectures that integrate contextual data (weather, infrastructure, accidents) to improve real-time predictions.

Keywords: short-term traffic flow prediction, traffic flow prediction error, long short-term memory (LSTM) model, support vector machine for regression (SVR)

Acknowledgements. The authors would like to thank the Editorial board and the reviewers for their attentive attitude to the article and the specified comments that helped the authors to improve its quality.

For Citation. Topilin IV, Han M, Feofilova AA, Beskopylny NA. Comparative Analysis of Neural Network and Machine Learning Models for Short-Term Traffic Flow Prediction on Shenzhen Expressway. *Advanced Engineering Research (Rostov-on-Don)*. 2025;25(4):350–362. <https://doi.org/10.23947/2687-1653-2025-25-4-2215>

Введение. Решение актуальной общемировой проблемы эффективного управления транспортными потоками базируется на точном анализе и прогнозировании трафика. Развитие урбанизации и глобализации трансформирует и перегружает дорожно-транспортные системы, для регулирования которых требуются качественно новые и универсальные подходы. Очевидно, что таковыми могут быть нейросетевые решения и адекватные машинные модели. Их тестирование и обучение должно базироваться на данных, полученных в условиях скоростных магистралей мегаполисов. В этом случае результаты можно экстраполировать на аналогичные системы, т.е. крупные трассы с оживленным движением.

В рамках представленной научной работы использовалась информация, полученная в условиях Шэньчжэня. Это крупный город на юго-востоке Китая. Численность населения превышает 17,5 млн человек, автомобилизация ежегодно растет на 8 %. Как следствие, в мегаполисе обостряется проблема дорожных заторов на автотрассах, общая протяженность которых достигла 386 км¹. Стремительное развитие дорожной сети, с одной стороны, способствовало значительному экономическому росту самого молодого китайского мегаполиса, с другой — перегрузило транспортную сеть, привело к сбоям в ее работе [1]. Таким образом, проблема Шэньчжэня — это не локальная аномалия, а типичный пример «болезни успеха», с которой сталкиваются мегаполисы по всему миру. Сложившаяся ситуация прямо противоречит перечисленным ниже ключевым целям устойчивого развития (ЦУР) ООН².

ЦУР 3 «Хорошее здоровье и благополучие». Заторы — это не только потеря времени. Это источник хронического стресса, повышенного шума и, что самое важное, загрязнения воздуха (твёрдые частицы PM2.5, NOx). По данным ВОЗ, загрязнение воздуха — один из главных факторов риска для здоровья.

Здесь важно отметить, что электрификация транспорта, которую активно продвигает Шэньчжэнь, — это лишь часть решения. Необходима еще и декарбонизация за счет сокращения числа личных автомобилей.

ЦУР 9 «Индустриализация, инновации и инфраструктура». Хронические заторы снижают экономическую конкурентоспособность города. Потери от заторов увеличивают логистические издержки, снижают производительность труда и делают территории менее привлекательными для инвестиций.

ЦУР 11 «Устойчивые города и населенные пункты». Заторы делают города неустойчивыми. Они снижают эффективность городских систем, увеличивают временные и экономические издержки на перемещение, ухудшают доступ к основным услугам (здравоохранение, образование) и снижают качество жизни.

ЦУР 13 «Борьба с изменением климата». Транспортный сектор — один из основных источников парниковых газов. Заторы значительно увеличивают выбросы CO₂ на пассажиро-километр или тонно-километр для пассажирского и грузового транспорта соответственно.

Глобальный масштаб проблемы стимулирует научные изыскания в данной сфере. Одна из базовых задач эффективного управления транспортными потоками — их качественное оперативное (краткосрочное) прогнозирование. В настоящее время эта задача не решена, что доказывает представленный ниже анализ литературных источников. Изложенные в них данные в большинстве случаев или фрагментарны, или не учитывают специфику высокоскоростных магистралей.

Краткосрочное прогнозирование транспортных потоков (STTFP) как ключевая задача интеллектуальных транспортных систем (ИТС) позволяет проактивно управлять заторами через динамическое ценообразование, оптимизацию маршрутов и оперативное реагирование на дорожные происшествия [2]. Однако нелинейный, сезонный и стохастический характер дорожного движения ограничивает эффективность традиционных статистических методов прогнозирования [3]. В качестве примеров можно привести интегрированную модель авторегрессии — скользящего среднего ARIMA [4] и *k* ближайших соседей (*k*NN), которые далеко не всегда адекватно отражают сложные пространственно-временные зависимости [5].

Последние достижения в области глубокого машинного обучения произвели революцию в краткосрочном прогнозировании транспортных потоков. Модели долгой краткосрочной памяти (LSTM) с архитектурой ячеек памяти превосходно воспроизводят последовательные данные и идеально подходят для прогнозирования дорожного движения [6]. Есть свои преимущества и у метода опорных векторов для регрессии (SVR) [7]. Он основан на ядрах, надежен и вычислительно эффективен в многомерных пространствах [8]. Развитие машинного обучения также способствовало активному использованию SVR, применяющего приемы ядра для работы с нелинейными зависимостями [9]. Модели глубокого обучения, особенно LSTM, доминируют в последних исследованиях STTFP [10].

Сравнительный анализ LSTM и SVR показал хорошую применимость этих методов при различных неравномерностях интенсивности дорожного движения. Кроме того, доказана высокая точность прогнозирования скорости транспортного потока [11].

¹ China Statistical Yearbook 2023. URL: <https://www.stats.gov.cn/sj/ndsj/2023/indexeh.htm> (дата обращения: 06.10.2025).

² Цели в области устойчивого развития. Организация объединенных наций. URL: <https://www.un.org/sustainabledevelopment/ru/sustainable-development-goals/> (дата обращения: 21.10.2025).

Несмотря на широкое применение этих методов, все еще мало сравнительных исследований для автомагистралей с интенсивными, высокоскоростными потоками. Есть некоторая информация о точечных объектах — городских перекрестках или локальных участках автомагистралей. При этом недостаточно исследований с комплексным анализом сети магистралей.

Представленная работа призвана восполнить этот пробел. Для сопоставления LSTM и SVR в качестве примера взяли автомагистраль Мэйгуан в китайском мегаполисе Шэньчжэнь. Цель работы — сравнительный анализ точности моделей LSTM и SVR и выбор оптимального подхода для прогнозирования транспортного потока на скоростной автомагистрали Мэйгуан Шэньчжэня. Для достижения цели авторы сформировали комплексный подход к предварительной обработке данных и извлечению признаков. Исследовался потенциал практического применения моделей в системах ИТС.

Материалы и методы. Автомагистраль Мэйгуань (рис. 1), расположенная в г. Шэньчжэнь (провинция Гуандун, Китай), представляет собой участок протяженностью 19,3 км в составе скоростной автомагистрали G94 (кольцевая дорога дельты Жемчужной реки). Расчетная скорость движения — 100 км/ч.

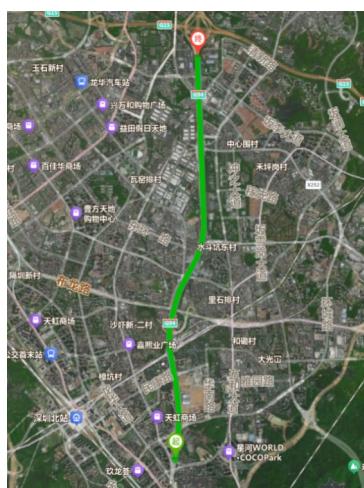


Рис. 1. Опытный отрезок скоростной автомагистрали Мэйгуань (скриншот карты из открытых источников)

Объект исследования — направление автомагистрали Мэйгуань с юга на север. Данные собирались с помощью шести индукционных петлевых детекторов (ILD), установленных на внутренних и внешних полосах движения.

С 5-минутным интервалом регистрировались следующие параметры:

- интенсивность дорожного движения (ед./5 минут);
- занятость детектора (%);
- средняя скорость (км/ч);
- дата и временной интервал (5 минут);
- период наблюдения: 7 дней (с 15 по 21 июня 2021 года).

Общий объем данных: 1144 записи.

Для повышения качества анализа и моделирования провели предварительную обработку данных [12]. Ниже перечислены ее этапы.

1. Скрининг данных. Выборка из набора для идентификации данных — валидных и соответствующих модели. Первоначально исходный набор данных разделяется по датам для отбора записей с наиболее полными данными, без явных пропусков. Удаляются невалидные, с явными пропусками. Из отобранных дат с полными данными выбираются последовательные даты для исследования временных вариаций потока.

2. Восполнение недостающих данных. Для обеспечения корректного сбора данных оборудование должно работать бесперебойно. Этому препятствуют такие случайные факторы, как неисправности, сбой в работе детектора транспорта, погодные условия, перебои с электроснабжением и др. Поэтому собранные данные иногда неполны и содержат пропуски. Однако в них может быть важная информация о закономерностях процесса. В итоге модель прогнозирования не получает достаточно данных, становится нестабильной, что снижает надежность прогнозирования. Таким образом, перед построением модели прогнозирования необходимо восполнить недостающие данные.

Для восполнения периодически возникающих временных пропусков в данных о транспортном потоке в представленной работе применяется метод взвешенного среднего [13].

Шаг 1. Получение среднего значения интенсивности дорожного движения за n моментов времени, предшествующих текущему моменту:

$$f_1(t) = \frac{f^k(t-1) + f^k(t-2) + \dots + f^k(t-n)}{n}.$$

Шаг 2. Среднее значение интенсивности дорожного движения на текущий момент, за предыдущие m дней:

$$f_2(t) = \frac{f^{(k-m)}(t) + f^{(k-(m-1))}(t) + \dots + f^{(k-1)}(t)}{m}.$$

Шаг 3. Восполнение недостающих данных:

$$f^{(k)}(t) = af_1(t) + (1-a)f_2(t),$$

где $f^{(k)}(t)$ — восстановление данных о транспортном потоке на момент t дня k , a — весовой коэффициент, $a = 0,6$.

Метод является основным при работе с пропущенными данными. Он учитывает такие свойства данных об интенсивности дорожного движения, как:

– циклическая природа — $f_1(t)$;

– временная природа — $f_2(t)$, т.е. влияние данных об интенсивности дорожного движения из предыдущих временных моментов.

3. Нормализация. Данные о транспортном потоке могут значительно варьироваться в зависимости от времени суток, участка дороги и других факторов, что приводит к большому разбросу значений. Функция активации некоторых нейронных узлов принимает значения в диапазоне $[0, 1]$. Поэтому перед обучением проводится нормализация [14]. Она позволяет устраниить влияние выбросов в данных (образцов, значительно отклоняющихся от других), а также ускоряет обучение сети, улучшает сходимость.

Основные методы нормализации: линейная, нелинейная и нормализация к 0-среднему. Функция активации принимает значения от 0 до 1, поэтому в представленной статье используется метод максимума-минимума линейной нормализации для преобразования значений транспортного потока в диапазон $[0, 1]$:

$$f(t) = \frac{f - f_{min}}{f_{max} - f_{min}},$$

где f — необработанные данные о транспортных потоках; f_{min} — минимальное значение в данных о транспортном потоке; f_{max} — максимальное значение в данных о транспортном потоке; $f(t)$ — нормализованное значение транспортного потока.

Обработанные данные редуцируются с использованием формулы обратной нормализации после вывода диагностической модели:

$$f = (f_{max} - f_{min})f(t) + f_{min}.$$

Частота выборки данных — 5 минут, итоговый объем предобработанных данных — 3168 записей. Некоторые из них, полученные 17 июня 2021 года, представлены в таблице 1.

Таблица 1
Примеры предобработанных экспериментальных данных

Интенсивность дорожного движения, ед./5 мин	Занятость детектора, %	Скорость транспортного потока, км/ч	Временной интервал, 5 мин
258	13,93	83,62	1
255	14,48	79,88	2
223	12,08	82,25	3
340	18,39	82,04	4
254	13,86	83,3	5
263	13,98	84,87	6
231	12,49	85,89	7
151	7,87	84,94	8
223	11,96	83,81	9
226	11,95	86,92	10
166	8,59	86,17	11
140	7,45	83,29	12

Интенсивность дорожного движения, ед./5 мин	Занятость детектора, %	Скорость транспортного потока, км/ч	Временной интервал, 5 мин
143	7,85	83,99	13
231	12,67	84,71	14
147	7,55	89,53	15
96	4,90	90,74	16
128	7,02	83,94	17
106	5,75	81,99	18
128	7,24	79,4	19
136	6,99	84,57	20

Извлечение признаков — ключевой этап построения эффективной модели прогнозирования транспортных потоков. Анализ и обработка данных о дорожном движении дают ключевую информацию о признаках, что позволяет повысить производительность и точность модели.

1. Извлечение признаков с временным лагом.

Данные одних временных рядов зависят от других временных рядов, и функция автокорреляции (ACF) описывает корреляцию временного ряда с различными лагами (Lag), то есть степень линейной корреляции между самим рядом и его собственными лагированными значениями [15]. Так определяется взаимосвязь между текущими и прошлыми значениями. При анализе временных рядов представляет интерес взаимосвязь между текущим значением Y_{t-k} и его значением Y_t в некоторый прошлый момент времени. Период лага k (Lag k) — это временной интервал между текущей точкой времени t и k -й точкой времени в прошлом $t-k$.

При прогнозировании транспортных потоков ACF использовалась для определения периодичности и тренда во временных рядах данных. Это позволило выбрать подходящий шаг лага в качестве признака и отразить динамику изменения параметров транспортных потоков (рис. 2).

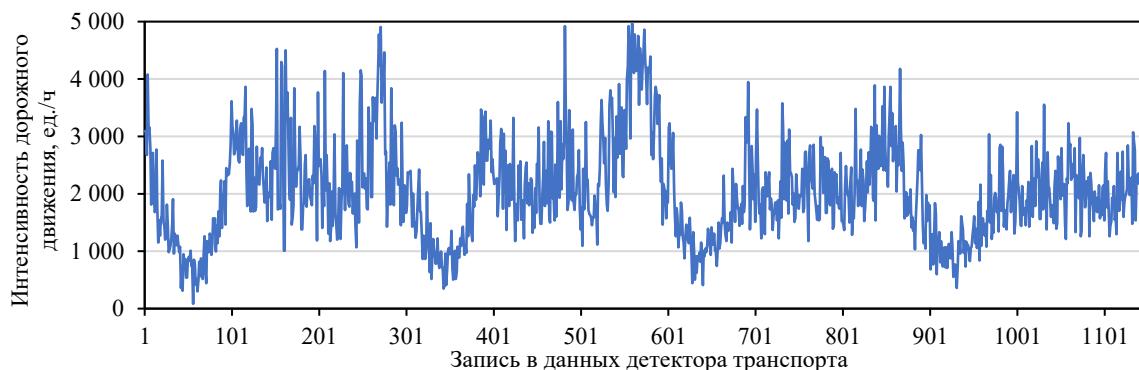


Рис. 2. Динамика интенсивности дорожного движения на автомагистрали Мэйгуань

Для временного ряда данных о транспортном потоке рассчитали ACF и проанализировали корреляцию между различными временными лагами (например, $t-1, t-2, \dots, t-n$) и текущим моментом t . Результаты вычислений представлены на рис. 3.

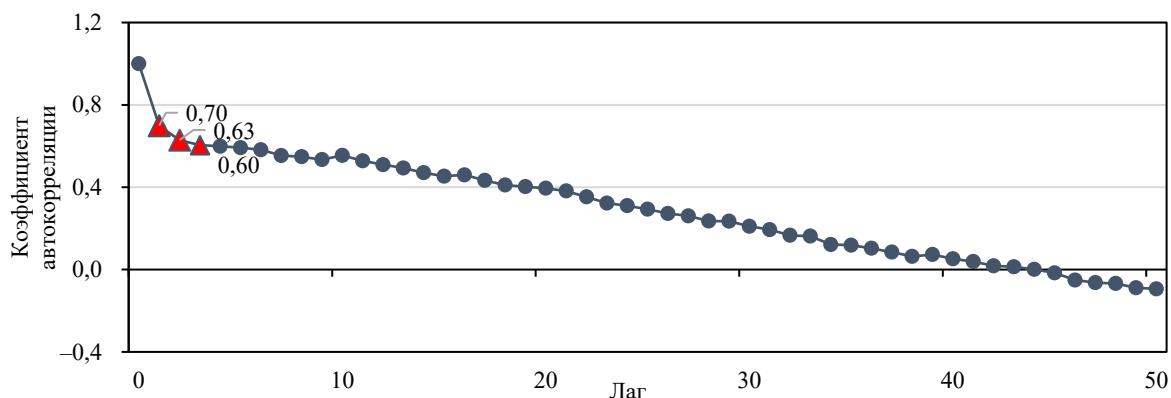


Рис. 3. Коэффициенты автокорреляции для различных шагов лага

Методом пороговой фильтрации ACF отобрали три временных лага с коэффициентом автокорреляции $>0,6$: (Lag 1: 0,70, Lag 2: 0,63, Lag 3: 0,60). Эти лаги выбрали в качестве входных признаков модели. Такой подход усиливает способность модели улавливать временные закономерности и обеспечивает надежную основу данных для последующих прогнозных моделей.

2. Взаимодействие скорости и занятости детектора.

Произведение скорости и занятости детектора используется как комплексный показатель для представления закономерности пространственно-временного изменения транспортного потока [16]. Занятость детектора и скорость — важные метрики транспортного потока. Их произведение можно использовать как термин «взаимодействие признаков». То есть формируется новый признак, который лучше отражает сложность и динамику транспортного потока. Добавление терминов взаимодействия может улучшить выразительные и аппроксимирующие возможности моделей машинного обучения, особенно таких, как LSTM и SVR. Термины взаимодействия дают больше информации, помогают модели лучше понимать закономерности и взаимосвязи в данных.

Архитектура модели и оценочные показатели

1. Метод опорных векторов для регрессии (SVR) основан на расширении алгоритма метода опорных векторов (SVM) [17]. Модель SVR подходит для решения сложных задач нелинейной регрессии. Она хорошо адаптирует нелинейные характеристики данных о транспортных потоках, обладает высокой устойчивостью к выбросам и может адаптироваться к различным характеристикам данных, благодаря настройке функции ядра и параметров регуляризации. Поэтому в данной статье модель SVR используется в качестве сравнительной модели для прогнозирования транспортных потоков.

2. Модель нейронной сети долгой краткосрочной памяти (LSTM) — это вариант рекуррентной нейронной сети, которая специально разработана для решения задач с долгосрочными временными зависимостями [18]. Ориентированная рекуррентная нейронная сеть LSTM способна глубже выявлять временные зависимости в задачах прогнозирования и эффективно аппроксимировать нелинейные данные. Она также может длительное время сохранять информацию из временных рядов [19]. Так обеспечивается высокая эффективность модели при работе с данными, имеющими большие временные интервалы и высокую задержку. Известны преимущества LSTM в прогнозировании временных рядов и ее высокая точность в долгосрочных прогнозах [20]. Одновременно модель обладает хорошей робастностью и гибкостью, что позволяет применять ее для прогнозирования транспортных потоков в условиях координации «транспортное средство — дорога». Важно отметить, что в структуре LSTM комбинировались переменные взаимодействия и лаговые показатели для повышения точности прогнозирования.

В данной статье оценивается эффективность прогнозирования модели с использованием следующих представительных метрик производительности:

- средняя абсолютная ошибка;
- средняя абсолютная процентная ошибка;
- среднеквадратическая ошибка [21].

Такой подход позволяет:

- количественно оценить точность моделей LSTM и SVR;
- визуализировать расхождение между фактическим транспортным потоком и результатами его прогнозирования, полученными с помощью LSTM.

Для проверки статистически значимой разницы между ошибками прогнозирования моделей LSTM и SVR в данной работе используется знаковый ранговый тест Уилкоксона [22]. Это непараметрический тест в статистике для парных данных. Он особенно полезен для небольших выборок и когда данные не подчиняются нормальному распределению. Исходная гипотеза (H_0) теста заключается в том, что нет значимой разницы между ошибками прогнозирования моделей LSTM и SVR. P -значение — это значение вероятности, используемое для выявления значимой разницы между двумя связанными выборками. Если P меньше заданного уровня значимости (обычно 0,05), нулевая гипотеза отвергается. В этом случае предполагается, что распределение разницы между двумя выборками различно, то есть сумма рангов значимо различается. В рамках данной работы это докажет значимую разницу в эффективности прогнозирования LSTM и SVR. Ниже описаны шаги расчета.

Шаг 1: Вычисление разности ошибок прогнозирования между двумя моделями. Разность ошибок прогнозирования для каждого наблюдения вычисляется по формуле:

$$d_i = e_i^{(LSTM)} - e_i^{(SVR)}.$$

Шаг 2: Вычисление абсолютных значений разностей и их ранжирование.

Шаг 3: Вычисление сумм положительных и отрицательных рангов.

Шаг 4: Вычисление вероятности P по Уилкоксону и сравнение этого значения с критическим.

Результаты. В рамках представленного исследования для предобработки данных о транспортном потоке используется язык Python. Экспериментальная выборка — это данные о транспортном потоке с 17 по 20 июня 2021 года (таблица 2). Данные регистрировались с 5-минутными интервалами и содержат 1 144 записи. Для прогнозирования транспортного потока и оценки моделей данные разделены на обучающую и тестовую выборки.

Таблица 2
Статистическая информация о наборах данных

Индикатор	Интенсивность дорожного движения (ед./ч)
Минимальное значение	84
Максимальное значение	4968
Среднее значение	2052
Медиана	1944
Стандартное отклонение	864

Минимальное значение интенсивности дорожного движения — 84, а максимальное — 4968, что указывает на значительный разброс данных. Это свидетельствует о крайне низкой интенсивности движения в отдельные периоды суток (например, ранним утром) и чрезвычайно высокой — в часы пик. Среднее значение равно 2052, а медиана — 1944. Тот факт, что медиана немного меньше среднего значения, указывает на правостороннюю асимметрию распределения данных. Значит, в большинстве временных промежутков интенсивность движения высока, тогда как некоторые периоды с низкой интенсивностью (в основном ранним утром и поздней ночью) снижают общее среднее значение. Стандартное отклонение, равное 864, подтверждает значительные колебания потока и резкие изменения интенсивности движения. Таким образом, набор данных пригоден для исследования долгосрочных зависимостей и нелинейных характеристик временных рядов и может служить экспериментальной выборкой для прогнозирования транспортных потоков.

Как отмечалось выше, для повышения эффективности прогнозирования в данном исследовании в качестве входных признаков взяли лаговую характеристику и переменную взаимодействия скорости и занятости детектора. Это позволяет полностью учесть взаимосвязи между информацией временного ряда и характеристиками потока.

Метод SVR использует радиальную базисную функцию (RBF-ядро) в качестве ядра для регистрации нелинейных взаимосвязей.

Ключевые параметры:

- 1) штрафной коэффициент $C = 2$ (контроль допустимой ошибки);
- 2) максимальное количество итераций — 120.

Ниже описаны параметры LSTM, использованные в данном исследовании.

- 1) Входной слой: временной шаг — это шаг задержки извлечения признаков, который равен 1, 2, 3.
- 2) Скрытый слой: однослойная структура LSTM, содержащая 150 ячеек, использующая функцию активации \tanh .
- 3) Регуляризация: используется механизм исключения 10 % для предотвращения переобучения.
- 4) Выходной слой: полносвязный слой, использующий линейную функцию активации для обеспечения непрерывности прогнозируемых значений.

5) Стратегия обучения: оптимизатор Adam, скорость обучения — 0,08, размер пакета — 128, количество раундов обучения (эпох) — 120.

На рис. 4 и 5 показаны результаты сравнения прогнозируемых и истинных значений для моделей LSTM и SVR.

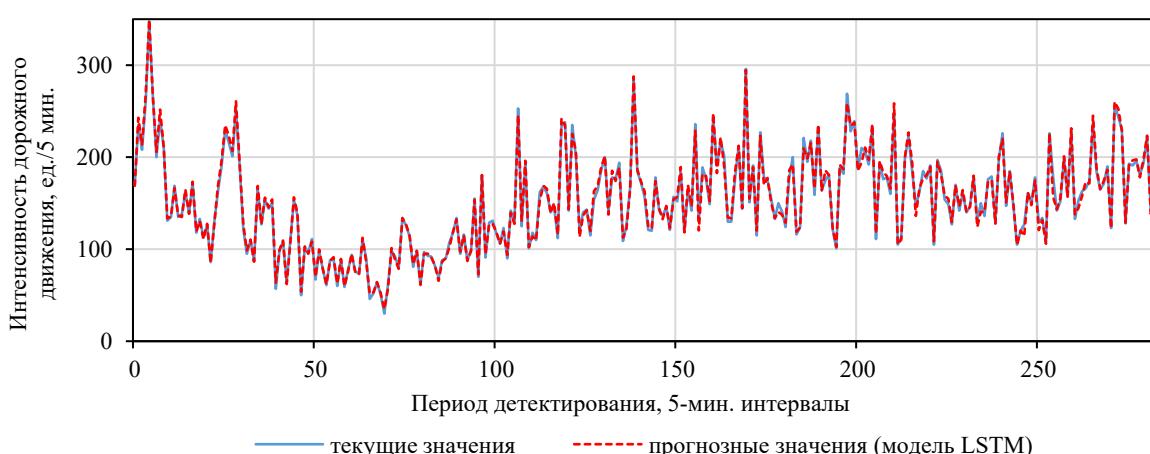


Рис. 4. Сравнение прогнозируемых и истинных значений LSTM

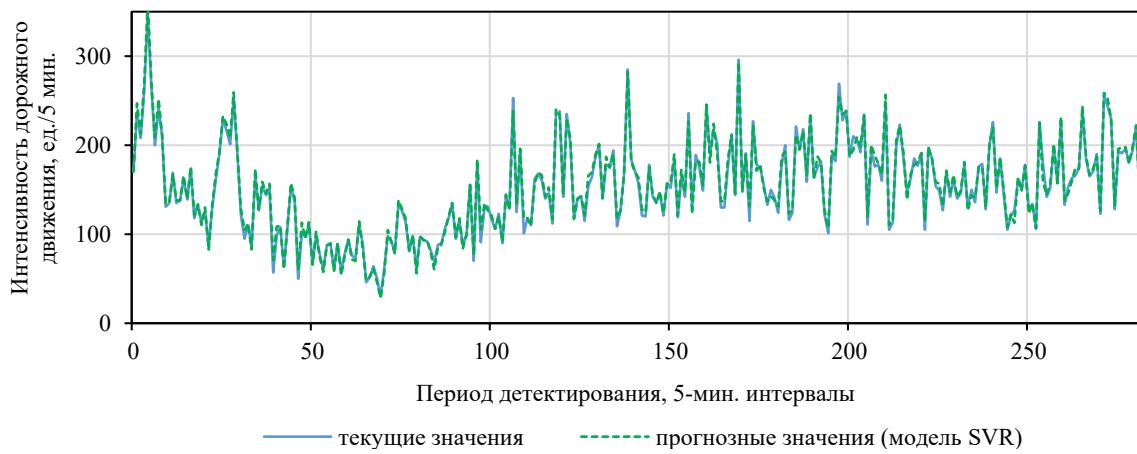


Рис. 5. Сравнение прогнозируемых и истинных значений SVR

Из графиков видно, что прогнозные значения моделей LSTM и SVR хорошо воспроизводят реальную динамику транспортного потока, диапазон ошибок прогнозирования небольшой. Поэтому указанные модели выбрали в качестве контрольных для дальнейшей оценки эффективности различных методов при прогнозировании транспортного потока.

Для повышения достоверности экспериментальных результатов и дополнительной проверки эффективности прогнозных моделей в рамках данного исследования провели 10 запусков обучения с различными случайными начальными значениями. В каждом эксперименте регистрировали результаты по среднеквадратическим ошибкам (RMSE), средним абсолютным ошибкам (MAE) и средним абсолютным процентным ошибкам (MAPE).

Для более наглядной оценки прогнозной эффективности в качестве основного показателя выбрали RMSE. Из 10 экспериментов для каждой модели отобрали пять лучших результатов, по которым рассчитывались средние значения для сравнительного анализа.

По данным таблицы 3 можно судить о точности прогнозирования моделей LSTM и SVR. Ошибки RMSE, MAE и MAPE для модели LSTM оказались меньше на 17,86 %, 19,82 % и 25,78 % соответственно, что позволяет говорить о ее более высокой прогнозной точности. MAPE отражает процент ошибки прогноза относительно реальных значений. Более низкий показатель MAPE свидетельствует о меньших относительных ошибках LSTM на различных уровнях потока. LSTM демонстрирует стабильность прогнозов как в пиковые, так и в минимальные периоды, тогда как SVR более чувствителен к экстремальным значениям.

Таблица 3

Ошибки прогнозирования моделей LSTM и SVR

Модель	RMSE	MAE	MAPE
LSTM	4,6	3,48	2,39 %
SVR	5,6	4,34	3,22 %

На рис. 6 показана абсолютная процентная ошибка прогнозных значений относительно реальных для каждого временного интервала вдоль временного ряда потока. Четко видно, что абсолютная процентная ошибка модели LSTM ниже в большинстве временных точек.

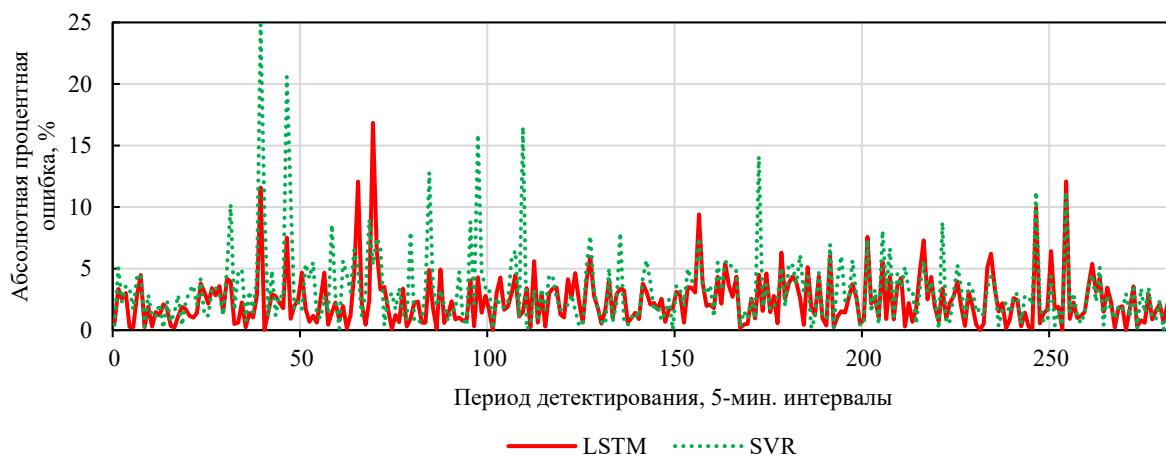


Рис. 6. Абсолютная процентная ошибка для различных временных срезов LSTM и SVR

Сопоставление рис. 6 с рис. 4 (реальные значения) показывает, что пики на графике с большими ошибками прогнозирования соответствуют временным интервалам с резкими изменениями интенсивности потока. LSTM дает более стабильные результаты прогнозирования и превосходит SVR в захвате пиков потока с нелинейными динамическими изменениями.

Из рис. 6 извлекли временные интервалы с наибольшей ошибкой (36–72) и с наименьшей ошибкой (108–144). Цифры — это номера интервалов длительностью 5 минут. Данные с указанных двух периодов использовали в обучении моделей и прогнозировании транспортного потока для сравнения способности LSTM и SVR к захвату динамических характеристик транспортного потока. На рис. 7 представлены результаты прогнозирования моделей LSTM и SVR для двух указанных временных периодов в сравнении с фактическими значениями.

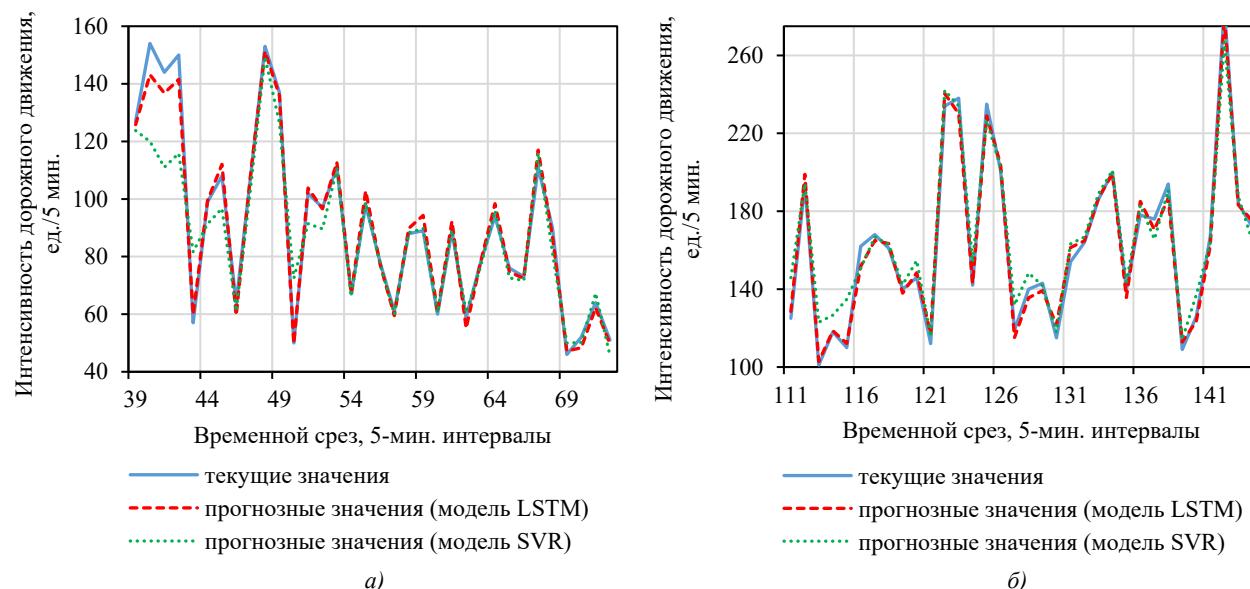


Рис. 7. Кривые прогнозов по временным периодам:

а — для временных срезов с наибольшей ошибкой; б — для временных срезов с наименьшей ошибкой

В таблице 4 представлены результаты прогнозирования двух моделей по периодам с наибольшими и наименьшими ошибками.

Таблица 4

Данные о наименьших и наибольших ошибках прогнозирования LSTM и SVR

Период	Model	RMSE	MAE	MAPE
С наименьшей ошибкой	LSTM	6,14	4,84	2,99 %
	SVR	9,67	7,37	5,19 %
С наибольшей ошибкой	LSTM	3,32	2,57	2,88 %
	SVR	12,39	7,43	8,09 %

Сравнение показывает, что LSTM демонстрирует лучшую точность в периодах с наименьшей ошибкой прогнозирования интенсивности потока: ошибки RMSE, MAE и MAPE для модели LSTM оказались меньше на 36,5 %, 34,3 % и 42,3 % соответственно. В периодах с наибольшей ошибкой прогнозирования интенсивности потока преимущество LSTM особенно заметно: ошибки RMSE, MAE и MAPE для модели LSTM оказались меньше на 73,2 %, 65,4 % и 64,4 % соответственно. Это свидетельствует о более высокой адаптивности данной модели.

Для статистической проверки значимости различий между моделями применили критерий знаковых рангов Уилкоксона. Результат ($P = 2,44\text{e-}15$) существенно меньше 0,05. Значит, следует отвергнуть нулевую гипотезу об отсутствии различий в ошибках прогнозирования. Это доказывает статистически значимое различие в эффективности моделей.

В сочетании с оценкой по RMSE, MAE и MAPE подтверждается, что ошибка LSTM намного меньше, а распределение ошибок более сконцентрировано, что свидетельствует о более высокой стабильности прогнозов. Результаты убедительно демонстрируют преимущества LSTM при работе с данными временных рядов транспортных потоков.

Обсуждение. Итак, качество прогноза зависит от архитектуры модели. Комбинирование переменных взаимодействия и лаговых показателей в структуре LSTM обусловило лучшую точность прогнозирования. Эксперименты позволили установить, что LSTM превосходит SVR по среднеквадратическим, средним абсолютным и средним абсолютным процентным ошибкам. Это подтверждает ее более высокую прогнозную способность при различных состояниях транспортного потока. Стабильность потока влияет на точность прогноза, однако LSTM, благодаря лучшим возможностям моделирования временных рядов, способна более эффективно учитывать временные зависимости потока и сохранять высокую точность даже в условиях значительных колебаний. Отметим, что LSTM не только эффективно учитывает временную зависимость транспортного потока, но и адаптируется к его сложным, долгосрочным динамическим изменениям. Отсюда — более точные результаты краткосрочного прогнозирования.

Преимущества LSTM оказались значительно нагляднее в периодах с наибольшей ошибкой прогнозирования интенсивности потока. Так, выигрыш этой модели по абсолютной процентной ошибке в периодах с наименьшей ошибкой достиг 42,3 %, с наибольшей — 64,4 %. Для RMSE и MAE разница двукратная или почти двукратная. Показатели для RMSE — 36,5 % (периоды с наименьшей ошибкой) и 73,2 % (с наибольшей). Соответствующие показатели для MAE — 34,3 % и 65,4 %.

Метод SVR хорошо адаптирует нелинейные характеристики данных о транспортных потоках, устойчива к выбросам и может адаптироваться к различным характеристикам данных, благодаря настройке функции ядра и параметров регуляризации. Его вычислительная эффективность выше. Однако такая модель более чувствительна к шуму данных из-за сложности моделирования долгосрочной временной зависимости, что снижает стабильность прогнозирования, особенно в условиях динамических колебаний транспортного потока с большими ошибками. Прогнозная эффективность SVR ограничена более слабой, нелинейной аппроксимирующей способностью при резких изменениях потока из-за ограничений собственной архитектуры, и этим обусловлен существенный рост ошибок.

Заключение. В данном исследовании проведен сравнительный анализ производительности сетей долгой краткосрочной памяти (LSTM) и метода опорных векторов для регрессии (SVR) для задачи краткосрочного прогнозирования транспортного потока на скоростной автомагистрали Мэйгуань в Шэньчжэне. Модель LSTM оказалась на 17,86 % лучше SVR по среднеквадратической ошибке, на 19,82 % — по средней абсолютной ошибке и на 25,78 % — по средней абсолютной процентной ошибке.

В пользу LSTM говорит и ее более высокая точность в периодах как с наименьшей ошибкой, так и с наибольшей. В первом случае в сравнении с SVR ошибки LSTM оказались меньше на 34,3–42,3 %, во втором — на 64,4–73,2 %.

Таким образом, при краткосрочном прогнозировании транспортного потока на скоростной автомагистрали, выбирая между нейросетевой и машинной моделью, следует предпочесть нейросетевую — в данном случае LSTM.

Обозначим три основных итога данного исследования для решения проблемы качественного краткосрочного прогнозирования транспортных потоков в крупных городах.

1. На примере скоростной автомагистрали Шэньчжэня экспериментально доказано, что LSTM как часть интеллектуальной транспортной системы достаточно надежно прогнозирует транспортные потоки.

2. Качественно оценены различия в точности прогнозирования между моделями LSTM и SVR, что обеспечивает объективную основу для выбора алгоритмов при построении систем управления дорожным движением. Статистический анализ подтвердил значимость различий.

3. Ниже сформулированы выводы, важные для практики управления дорожным движением на автотрассах крупных городов.

- LSTM эффективно адаптируется к временным характеристикам транспортных потоков на магистралях.
- LSTM обеспечивает точные прогнозы даже в условиях резких колебаний интенсивности движения.
- Результаты исследования позволяют разрабатывать предиктивные стратегии снижения заторов.

Краткосрочное прогнозирование транспортного потока на основе LSTM позволяет относительно точно предсказывать интенсивность дорожного движения. Это может быть базой для оптимизации стратегий управления дорожным движением, снижения заторов и выбросов загрязняющих веществ, а также для оптимизации интеллектуальных транспортных систем.

Перспективное направление дальнейших исследований — разработка гибридных архитектур, интегрирующих контекстные данные (например, сведения о погодных условиях, дорожных инцидентах или особенностях инфраструктуры). Это позволит повысить достоверность и устойчивость прогнозов в режиме реального времени.

Список литературы / References

1. Garg T, Kaur G. A Systematic Review on Intelligent Transport Systems. *Journal of Computational and Cognitive Engineering*. 2022;2(3):175–188. <https://doi.org/10.47852/bonviewJCCE2202245>

2. Vlahogianni EI, Matthew GK, Golias JC. Short-Term Traffic Forecasting: Where We Are and Where We're Going. *Transportation Research. Part C: Emerging Technologies*. 2014;43(1):3–19. <https://doi.org/10.1016/j.trc.2014.01.005>
3. Williams BM, Hoel LA. Modeling and Forecasting Vehicular Traffic Flow as a Seasonal ARIMA Process: Theoretical Basis and Empirical Results. *Journal of Transportation Engineering*. 2003;129(6):664–672. [https://doi.org/10.1061/\(ASCE\)0733-947X\(2003\)129:6\(664\)](https://doi.org/10.1061/(ASCE)0733-947X(2003)129:6(664))
4. Lippi M, Bertini M, Frasconi P. Short-Term Traffic Flow Forecasting: An Experimental Comparison of Time-Series Analysis and Supervised Learning. *IEEE Transactions on Intelligent Transportation Systems*. 2013;14(2):871–882. <https://doi.org/10.1109/TITS.2013.2247040>
5. Zhenjin Huang, Hao Ouyang, Yiming Tian. Short-Term Traffic Flow Combined Forecasting Based on Nonparametric Regression. In: *Proc. International Conference of Information Technology, Computer Engineering and Management Sciences*. New York City: IEEE; 2011. P. 316–319. <https://doi.org/10.1109/ICM.2011.89>
6. 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>
7. Ceperic E, Ceperic V, Baric A. A Strategy for Short-Term Load Forecasting by Support Vector Regression Machines. *IEEE Transactions on Power Systems*. 2013;28(4):4356–4364. <https://doi.org/10.1109/TPWRS.2013.2269803>
8. Weiwei Zhu, Jinglin Wu, Ting Fu, Junhua Wang, Jie Zhang, Qiangqiang Shangguan. Dynamic Prediction of Traffic Incident Duration on Urban Expressways: A Deep Learning Approach Based on LSTM and MLP. *Journal of Intelligent and Connected Vehicles*. 2021;4(2):80–91. <https://doi.org/10.1108/JICV-03-2021-0004>
9. Peng Chen, Yong-zai Lu. Extremal Optimization for Optimizing Kernel Function and Its Parameters in Support Vector Regression. *Journal of Zhejiang University Science C*. 2011;12:297–306. <https://doi.org/10.1631/jzus.C1000110>
10. Feihu Ma, Shiqi Deng, Sang Mei. A Short-Term Highway Traffic Flow Forecasting Model Based on CNN-LSTM with an Attention Mechanism. *Journal of Physics: Conference Series*. 2023;2491:012008. <https://doi.org/10.1088/1742-6596/2491/1/012008>
11. Liu Mingyu, Wu Jianping, Wang Yubo, He Lei. Traffic Flow Prediction Based on Deep Learning. *Journal of System Simulation*. 2018;30(11):4100–4106. URL: <https://dc-china-simulation.researchcommons.org/journal/vol30/iss11/7> (accessed 09.09.2025).
12. García S, Ramírez-Gallego S, Luengo J, Benítez JM, Herrera F. Big Data Preprocessing: Methods and Prospects. *Big Data Analytics*. 2016;1:9. <https://doi.org/10.1186/s41044-016-0014-0>
13. Robin Kuok Cheong Chan, Joanne Mun-Yee Lim, Rajendran Parthiban. A Neural Network Approach for Traffic Prediction and Routing with Missing Data Imputation for Intelligent Transportation System. *Expert Systems with Applications*. 2021;171:114573. <https://doi.org/10.1016/j.eswa.2021.114573>
14. Chahinez Ounoughi, Sadok Ben Yahia. Sequence to Sequence Hybrid Bi-LSTM Model for Traffic Speed Prediction. *Expert Systems with Applications*. 2024;236:121325. <https://doi.org/10.1016/j.eswa.2023.121325>
15. Rong Chen, Lijian Yang, Christian Hafner. Nonparametric Multistep-Ahead Prediction in Time Series Analysis. *Journal of the Royal Statistical Society. Series B: Statistical Methodology*. 2004;66(3):669–686. <https://doi.org/10.1111/j.1467-9868.2004.04664.x>
16. Aqib M, Mehmood R, Alzahrani A, Katib I, Albeshri A, Altowajri SM. Smarter Traffic Prediction Using Big Data, In-Memory Computing, Deep Learning and GPUs. *Sensors*. 2019;19(9):2206. <https://doi.org/10.3390/s19092206>
17. Xianyao Ling, Xinxin Feng, Zhonghui Chen, Yiwen Xu, Haifeng Zheng. Short-Term Traffic Flow Prediction with Optimized Multi-kernel Support Vector Machine. In: *Proc. IEEE Congress on Evolutionary Computation (CEC)*. New York City: IEEE; 2017. P. 294–300. <https://doi.org/10.1109/CEC.2017.7969326>
18. Zhou Zhao, Ashok Srivastava, Lu Peng, Qing Chen. Long Short-Term Memory Network Design for Analog Computing. *ACM Journal on Emerging Technologies in Computing Systems (JETC)*. 2019;15(1):1–27. <https://doi.org/10.1145/3289393>
19. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*. 2014;15:1929–1958. URL: https://www.jmlr.org/papers/volume15/srivastava14a/srivastava14a.pdf?utm_content=buffer79b4 (accessed: 21.10.2025).
20. Yang Zhu, Yijun Gao, Zhenhao Wang, Guansen Cao, Renjie Wang, Song Lu, et al. A Tailings Dam Long-Term Deformation Prediction Method Based on Empirical Mode Decomposition and LSTM Model Combined with Attention Mechanism. *Water*. 2022;14(8):1229. <https://doi.org/10.3390/w14081229>
21. Pan B, Demiryurek U, Shahabi C. Utilizing Real-World Transportation Data for Accurate Traffic Prediction. In: *Proc. IEEE 12th International Conference on Data Mining*. New York City: IEEE; 2012. P. 595–604. <https://doi.org/10.1109/ICDM.2012.52>
22. Moors G, Vriens I, Gelissen JP, Vermunt JK. Two of a Kind. Similarities Between Ranking and Rating Data in Measuring Values. *Survey Research Methods*. 2016;10(1):15–33. <https://doi.org/10.18148/srm/2016.v10i1.6209>

Об авторах:

Иван Владимирович Топилин, кандидат технических наук, доцент кафедры «Организация перевозок и дорожного движения» Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [SPIN-код](#), [ORCID](#), [ScopusID](#), ivan_top@mail.ru

Мэнни Хань, аспирант кафедры «Организация перевозок и дорожного движения» Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [ORCID](#), hanmengyi@mail.ru

Анастасия Александровна Феофилова, кандидат технических наук, доцент кафедры «Организация перевозок и дорожного движения» Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [SPIN-код](#), [ORCID](#), [ScopusID](#), afeofilova@donstu.ru

Никита Алексеевич Бескопыльный, аспирант кафедры «Организация перевозок и дорожного движения» Донского государственного технического университета (344003, Российская Федерация, г. Ростов-на-Дону, пл. Гагарина, 1), [SPIN-код](#), [ORCID](#), [ResearchGate](#), [ScopusID](#), nbeskopylnyi@donstu.ru

Заявленный вклад авторов:

И.В. Топилин: разработка концепции, научное руководство.

А.А. Феофилова: валидация результатов, написание рукописи – рецензирование и редактирование.

М. Хань: проведение исследования, анализ результатов, подготовка черновика научной статьи.

Н.А. Бескопыльный: проведение исследования, анализ результатов, подготовка черновика научной статьи.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Все авторы прочитали и одобрили окончательный вариант рукописи.

About the Authors:

Ivan V. Topilin, Cand.Sci. (Eng.), Associate Professor of the Department of Organization of Transportation and Road Traffic Management, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, Russian Federation), [SPIN-code](#), [ORCID](#), [ScopusID](#), ivan_top@mail.ru

Mengyi Han, Postgraduate student of the Department of Organization of Transportation and Road Traffic Management, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, Russian Federation), [ORCID](#), hanmengyi@mail.ru

Anastasia A. Feofilova, Cand.Sci. (Eng.), Associate Professor of the Department of Organization of Transportation and Road Traffic Management, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, Russian Federation), [SPIN-code](#), [ORCID](#), [ScopusID](#), afeofilova@donstu.ru

Nikita A. Beskopylny, Postgraduate student of the Department of Organization of Transportation and Road Traffic Management, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, Russian Federation), [SPIN-code](#), [ORCID](#), [ResearchGate](#), [ScopusID](#), nbeskopylnyi@donstu.ru

Claimed Contributorship:

IV Topilin: conceptualization, supervision.

AA Feofilova: validation, writing – review & editing.

M Han: investigation, validation, writing – original draft preparation.

NA Beskopylny: investigation, validation, writing – original draft preparation.

Conflict of Interest Statement: the authors declare no conflict of interest.

All authors have read and approved the final manuscript.

Поступила в редакцию / Received 18.08.2025

Поступила после рецензирования / Reviewed 11.09.2025

Принята к публикации / Accepted 29.09.2025