

**Є. В. БОЯРШИНОВ**

магістрант кафедри електронних обчислювальних машин  
Харківський національний університет радіоелектроніки  
ORCID: 0009-0001-5631-0951

**Г. С. ІВАЩЕНКО**

кандидат технічних наук, доцент,  
доцент кафедри електронних обчислювальних машин  
Харківський національний університет радіоелектроніки  
ORCID: 0000-0003-1027-5262

**І. А. СОЛОВЬІОВ**

магістрант кафедри електронних обчислювальних машин  
Харківський національний університет радіоелектроніки  
ORCID: 0009-0003-1874-6695

## НЕЙРОМЕРЕЖЕВІ МЕТОДИ ПРОГНОЗУВАННЯ ІНТЕНСИВНОСТІ ДОРОЖНЬОГО РУХУ

*Робота присвячена вирішенню задачі короткострокового прогнозування інтенсивності транспортних потоків з використанням сучасних архітектур штучних нейронних мереж, таких як SimpleRNN, LSTM, GRU та 1D-CNN. Вихідні дані для досліджень представлені у вигляді одновимірних часових рядів, що містять інформацію про кількість транспортних засобів на окремих перехрестях в різні моменти часу. Точність прогнозу таких рядів є важливою для задач адаптивного керування світлофорними об'єктами, планування режимів руху та оцінювання навантаження на дорожню інфраструктуру.*

*Поширені методи прогнозування часових рядів зазвичай базуються на статистичних моделях, які можуть бути недостатньо точними для опису нелінійної динаміки трафіку та вираженої добової й тижневої сезонності. Окремою проблемою є коректне врахування циклічних часових ознак (година доби, день тижня), для яких при звичайному аналізі часових рядів виникає розрив на межі циклу.*

*Запропонований підхід передбачає використання попередньої обробки даних, зокрема очищення від аномальних викидів та застосування тригонометричного кодування часових ознак (Cyclical Feature Encoding). Це дозволяє нейронним мережам коректно інтерпретувати добову та тижневу сезонність, зберігаючи безперервність часового циклу.*

*В ході дослідження проведені обчислювальні експерименти при різних горизонтах прогнозування (1-12 годин) з використанням реальних вихідних даних, що дозволило оцінити ефективність запропонованого підходу при короткостроковому прогнозуванні. Результати проведеного порівняльного аналізу демонструють зменшення помилки прогнозування (MAPE) порівняно з традиційними методами. Встановлено, що запропонована модель на основі архітектури одновимірної згортки (1D-CNN) демонструє найменший час навчання, тоді як LSTM та GRU забезпечують найвищу точність прогнозування. Отримані результати можуть бути використані при розробці адаптивних систем керування світлофорними об'єктами в рамках концепції «розумного міста».*

**Ключові слова:** інтенсивність трафіку, обробка даних, часові ряди, короткострокове прогнозування, штучні нейронні мережі, глибоке навчання, LSTM, GRU, CNN, RNN.

**YE. V. BOIARSHINOV**

Student at the Department of Electronic Computers  
Kharkiv National University of Radio Electronics  
ORCID: 0009-0001-5631-0951

**H. S. IVASHCHENKO**

Candidate of Technical Sciences, Associate Professor,  
Associate Professor at the Department of Electronic Computers  
Kharkiv National University of Radio Electronics  
ORCID: 0000-0003-1027-5262



I. A. SOLOVIOV

Student at the Department of Electronic Computers

Kharkiv National University of Radio Electronics

ORCID: 0009-0003-1874-6695

## NEURAL NETWORK METHODS FOR TRAFFIC INTENSITY FORECASTING

*This paper is dedicated to solving the problem of short-term traffic flow intensity forecasting using modern artificial neural network architectures, including SimpleRNN, LSTM, GRU, and 1D-CNN. The dataset for the research consists of one-dimensional time series containing counts of vehicles at specific intersections at various points in time. The accuracy of time series forecasting is crucial for tasks involving adaptive traffic light control, traffic mode planning, and road infrastructure load assessment.*

*Standard time series forecasting methods are typically based on statistical models, which may be insufficient for describing non-linear traffic dynamics and daily and weekly seasonality. A specific problem is the proper consideration of cyclical time features (hour of the day, day of the week), where standard encoding creates discontinuities at cycle boundaries.*

*The proposed approach involves data preprocessing, including outlier removal and trigonometric cyclical feature encoding. That allows neural networks to correctly interpret daily and weekly seasonality while maintaining the continuity of the time cycle.*

*During the study, computational experiments across various forecasting horizons (1–12 hours) were conducted using real-world data, enabling an evaluation of the proposed approach's effectiveness in short-term forecasting. The results of the comparative analysis demonstrate a reduction in the Mean Absolute Percentage Error (MAPE) compared to traditional methods. It was established that the 1D-CNN model achieves the shortest training time, while LSTM and GRU achieve the highest forecasting accuracy. The obtained results can be used to develop adaptive traffic-light control systems within the Smart City concept.*

**Key words:** traffic intensity, data processing, time series, short-term forecasting, artificial neural networks, deep learning, LSTM, GRU, CNN, RNN.

### Постановка проблеми

Прогнозування інтенсивності дорожнього руху є важливою складовою сучасних інтелектуальних транспортних систем (ITS) та концепції «розумного міста» [1]. Прогнозування передбачає використання накопичених історичних даних у вигляді часових рядів транспортних потоків, що відображають динаміку переміщення автомобілів перехрестями. Висока точність моделей прогнозування необхідна для задач адаптивного керування світлофорними об'єктами, оптимізації маршрутів та запобігання заторів [1-3].

Дорожній трафік характеризується стохастичністю, нелінійністю та вираженою добовою/тижневою сезонністю, що ускладнює його моделювання з використанням класичних лінійних підходів до аналізу часових рядів. Для прогнозування трафіку застосовують як традиційні статистичні моделі, так і алгоритми машинного навчання, зокрема штучні нейронні мережі [4].

Традиційні статистичні методи прогнозування часто виявляються неефективними в умовах різких змін інтенсивності трафіку та впливу зовнішніх факторів, таких як погодні умови (опаді, туман), обмеження дорожнього руху (перекриття вулиць, об'їзди), помилки у зібраних даних (пропуски даних, помилкові спрацювання, калібрування). Через це сучасні підходи до прогнозування переважно спираються на методи глибокого навчання, що використовують рекурентні (RNN, LSTM, GRU) та згорткові (CNN) нейронні мережі. Використання таких архітектур дозволяє виявляти закономірності (патерни) у великих масивах даних, проте потребує значних обчислювальних ресурсів для навчання та підбору гіперпараметрів [4-6].

Одним із перспективних напрямів підвищення ефективності систем прогнозування інтенсивності дорожнього руху є використання сучасних нейромережових архітектур у поєднанні з методами попередньої обробки даних, здатними враховувати циклічну природу трафіку. Актуальним завданням є досягнення високої точності прогнозування при достатній швидкодії, що забезпечить використання у системах реального часу [7-8].

### Аналіз останніх досліджень і публікацій

Застосування методів глибокого навчання для прогнозування інтенсивності дорожнього руху в інтелектуальних транспортних системах розглядається у сучасних наукових дослідженнях [9-11].

У [9] представлено аналіз ефективності використання нейромережових методів порівняно з класичними статистичними підходами, такими як моделі на основі ARIMA та історичного середнього (HA). Автори роботи розглядають застосування рекурентних архітектур (LSTM, GRU) для моделювання часових рядів трафіку, використовуючи їх здатність враховувати довготривалі часові залежності у вихідних даних.

Недоліком використаних рекурентних архітектур є послідовний характер обчислень, що унеможливує повне розпаралелювання процесу навчання та суттєво збільшує час обробки даних при роботі в режимі реального часу. Можливим рішенням є використання згорткових архітектур (таких як 1D-CNN), що підтримують паралелізм обчислень та дозволяють суттєво зменшити часові витрати на навчання.

Дослідження [10] присвячено використанню часових згорткових мереж (TCN/CNN) для прогнозування транспортних потоків, що дозволяє обробляти дані в масово-паралельному режимі. Реалізація базується на використанні розширених згорткових фільтрів для врахування часових залежностей, що забезпечує більшу швидкість навчання порівняно з рекурентними мережами. Основним недоліком підходу є обмежене рецептивне поле згортки (обсяг контексту), що може призводити до втрати інформації про сезонність без застосування спеціальних методів попередньої обробки.

Дослідження [11] зосереджене на розробці гібридних архітектур, що поєднують згорткові (CNN) та рекурентні (BiGRU) шари для спільного врахування різних закономірностей у даних часових рядів транспортних потоків. Підхід дозволяє підвищити точність прогнозування на нестационарних даних та за умов наявності шуму, викидів і пропусків. Недоліком запропонованого авторами гібридного рішення є висока архітектурна складність та значна кількість параметрів, що потребує ретельного налаштування гіперпараметрів для запобігання перенавантаженню, ускладнюючи практичне впровадження.

Розглянуті дослідження нейромережових підходів до прогнозування підтверджують доцільність використання сучасних архітектур штучних нейронних мереж, з урахуванням можливості попередньої обробки даних для підвищення точності та розпаралелювання для збільшення швидкодії у системах короткострокового прогнозування трафіку.

### Формулювання мети дослідження

Метою роботи є розробка та дослідження ефективності методів короткострокового прогнозування часових рядів інтенсивності дорожнього руху на основі сучасних нейромережових архітектур (LSTM, GRU, 1D-CNN та SimpleRNN). Використання нейромережових методів передбачає формування на основі вихідного набору даних навчальних вибірок за допомогою ковзного вікна [10], застосування попередньої обробки даних (очищення від викидів і тригонометричне кодування часових ознак). Для оцінки ефективності проводиться порівняльний аналіз за показниками похибки прогнозу (MAE, MAPE, RMSE) та швидкості навчання на різних горизонтах (1–12 год).

### Викладення основного матеріалу дослідження

Прогнозування інтенсивності дорожнього руху в інтелектуальних транспортних системах (ITS) розглядається як задача короткострокового прогнозування часових рядів. Нехай  $x_t \in R$  – інтенсивність трафіку (кількість транспортних засобів), фіксована у момент часу  $t$ . Завданням нейромережової моделі  $F$  є прогнозування значення  $x_{t+h}$  на горизонті прогнозування  $h$  на основі фрагмента часового ряду вихідних даних довжиною  $L$  (Lookback):

$$\hat{x}_{t+h} = F(x_{t-L+1}, x_{t-L+2}, \dots, x_t; \theta), \quad (1)$$

де  $\theta$  – параметри моделі, що оптимізуються під час навчання,  $L$  – розмір вікна передісторії.

Навчання нейромережових моделей виконується за допомогою градієнтних методів оптимізації, тому для стабілізації та пришвидшення збіжності значення цільової змінної піддаються Z-score нормалізації:

$$x'_t = \frac{(x_t - \mu)}{\sigma}, \quad (2)$$

де  $\mu$  – середнє значення інтенсивності трафіку, а  $\sigma$  – стандартне відхилення оцінки інтенсивності трафіку у навчальній вибірці.

Вхідні дані проходять багатоетапну попередню обробку. У ході дослідження було реалізовано та протестовано три стратегії підготовки даних: базову нормалізацію (тип А), згладжування ковзним середнім (тип В) та розширену підготовку даних з очищенням аномальних викидів і врахуванням сезонних компонент (тип С).

При нормалізації даних не використовує додаткового шумозаглушення. Дані передаються на вхід моделі у вихідному вигляді, проходячи лише обов'язковий етап Z-score нормалізації (2).

Згладжування ковзним середнім (тип В) передбачає підготовку із застосуванням алгоритму Simple Moving Average (SMA) для фільтрації високочастотного локального шуму. Згладжене значення  $x_t^{(B)}$  інтенсивності трафіку у момент часу  $t$  обчислюється згідно:

$$x_t^{(B)} = \frac{1}{k} \sum_{i=0}^{k-1} x_{t-i}, \quad (3)$$

де  $k$  – розмір вікна згладжування (у рамках експерименту обрано  $k = 3$  години). Згладжування дозволяє зменшити вплив випадкових короткочасних коливань на процес навчання.

Обробка аномалій реалізовано методом вінзоризації. Алгоритм обмежує максимальні значення інтенсивності на рівні 99-го перцентиля ( $P_{99}$ ), розрахованого на навчальній вибірці:

$$x_t^{(C)} = \begin{cases} x_t, & \text{якщо } x_t \leq P_{99} \\ P_{99}, & \text{якщо } x_t > P_{99} \end{cases} \quad (4)$$

Експериментально встановлено, що при параметрі  $L=168$  (використання даних за 168 годин) та  $h=1$  (прогнозування на один крок уперед), застосування стратегії попередньої обробки типу C забезпечує суттєве зменшення середньої абсолютної помилки (MAE). Результати представлено в таблиці 1.

Таблиця 1

**Вплив попередньої обробки (типів А та С) на MAE**

Модель	MAE (тип А), авто/год	MAE (тип С), авто/год	Зменшення, %
GRU	3.45	2.15	-37.7
LSTM	3.36	2.18	-35.3
SimpleRNN	3.34	2.32	-30.4
1D-CNN	6.14	5.60	-8.9

Трафік має виражену добову та тижневу сезонність, тому часові ознаки доцільно подавати з урахуванням їхньої циклічної природи. При використанні ознак година доби  $h \in [0,6]$  та день тижня  $d \in [0,6]$  виникає проблема розриву вихідного часового ряду на межі циклу (наприклад, перехід 23:00 → 00:00): значення, близькі в часі, стають віддаленими при звичайному числовому поданні. Для усунення цієї проблеми застосовано тригонометричне (циклічне) кодування.

Часова змінна  $t$  з періодом  $T$  трансформується у дві компоненти:

$$x_{sin} = \sin\left(\frac{2\pi t}{T}\right), x_{cos} = \cos\left(\frac{2\pi t}{T}\right) \tag{5}$$

Для комплексної оцінки ефективності моделей обрано метрики похибки (MAPE, RMSE) та показники часових витрат на навчання (час навчання однієї епохи). Експериментальна модель прогнозування була розгорнута у середовищі Jupyter Notebook із використанням бібліотек TensorFlow та Keras.

Використано відкритий набір даних Traffic Prediction Dataset [12], що містить погодинні дані про трафік на чотирьох дорожніх розв'язках за 2015–2017 роки (понад 48 000 записів). Для оцінки варіативності потоку транспортних засобів розраховано статистичний коефіцієнт варіації (CV), як відношення стандартного відхилення  $\sigma$  до середнього значення інтенсивності трафіку  $\mu$ . Більші значення CV відповідають більшій відносній мінливості інтенсивності трафіку (Таблиця 2).

Таблиця 2

**Характеристика наборів даних (Traffic Prediction Dataset)**

№ перехрестя	Кількість записів	Середній трафік (авто/год)	Стандартне відхилення	Коефіцієнт варіації (CV)
1	14 592	45.05	23.01	0.51
2	14 592	14.25	7.40	0.52
3	14 592	13.69	10.44	0.76
4	4 344	7.25	3.52	0.49

Формування вхідних багатовимірних масивів даних (тензорів) здійснюється методом ковзного вікна. Вектор ознак  $X_t$ , що є структурною одиницею вхідного тензора, включає історичні значення інтенсивності та тригонометричні часові компоненти  $\tau = (x_{sin}, x_{cos})$ :

$$X_t = \{(x_{t-L}, \tau_{t-L}), \dots, (x_{t-1}, \tau_{t-1})\} \tag{6}$$

Кількість використаних значень часового ряду 168 годин (1 тиждень), що дозволило врахувати тижневу сезонність. Порівнювалися моделі на основі чотирьох архітектур: SimpleRNN, LSTM, GRU та 1D-CNN (одновимірний згортка). Оцінка прогнозу виконувалася за метрикою MAPE:

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{(x_i - \hat{x}_i)}{\max(|x_i|, \epsilon)} \right| \tag{7}$$

Результати вимірювання часу навчання моделей на основі архітектур штучних нейронних мереж представлено в таблиці 3.

Висока швидкість навчання при використанні архітектур SimpleRNN та 1D-CNN порівняно з базовою моделлю на LSTM пояснюється структурними особливостями реалізованих моделей. 1D-CNN передбачає масово-паралельну обробку вхідного тензора за допомогою згорткових фільтрів, що усуває необхідність послідовних ітерацій, характерних для рекурентних зв'язків. Для SimpleRNN перевага досягається завдяки мінімальній обчислювальній

складності рекурентної комірки, яка, на відміну від LSTM та GRU, не містить механізмів вентилів, що зменшує кількість матричних операцій при кожному оновленні прихованого стану мережі.

Таблиця 3

**Порівняння часу навчання моделей**

Архітектура моделі	Час навчання однієї епохи, с	Повний час навчання, с	Прискорення
SimpleRNN	2.74	54.77	4.30
1D-CNN	3.13	62.64	3.76
GRU	11.67	173.78	1.01
LSTM (Base)	11.78	217.77	1.00


На короткому горизонті прогнозування (1 година) найкращу точність забезпечило використання моделей на основі LSTM та GRU (Таблиця 4).

Таблиця 4

**Точність прогнозування**

Модель	MAE (авто/год)	RMSE	MAPE (%)
LSTM	2.18	3.36	8.58
GRU	2.15	3.27	8.65
SimpleRNN	2.32	3.59	8.78
1D-CNN	5.60	8.10	22.51

Аналіз поведінки моделей на різних горизонтах (Рисунок 1) демонструє динаміку зростання помилки при збільшенні термінів прогнозування.



**Рис. 1. Помилка MAPE (%) при збільшенні горизонту прогнозу**

Аналіз результатів (рис. 1) показує, що зі збільшенням горизонту прогнозування значення MAPE зростає для всіх моделей. Модель LSTM зберігає найвищу точність завдяки ефективному врахуванню довгострокових часових залежностей.

Отримані результати доводять доцільність використання архітектур LSTM та GRU у системах, де пріоритетом є точність прогнозування. Модель 1D-CNN забезпечує кращу швидкодію на процесорах загального призначення (CPU), однак дозволяє можливість подальшого вдосконалення, шляхом розпаралелювання з використанням GPU.

Отримані значення точності рекурентних моделей значною мірою пояснюються використанням попередньої обробки даних, що включає адаптивну вінзоризацію та циклічне кодування часових ознак, підвищуючи якість представлення вхідних даних.

#### Висновки

Запропоновано підхід до короткострокового прогнозування часових рядів інтенсивності дорожнього руху в інтелектуальних транспортних системах, який базується на застосуванні архітектур глибоких нейронних мереж (SimpleRNN, LSTM, GRU, 1D-CNN) з використанням попередньої обробки вихідних даних, яка включає адаптивне очищення від викидів, Z-score нормалізацію та тригонометричне кодування циклічних часових ознак, що забезпечує врахування добової та тижневої сезонності транспортних потоків.

Експериментальні дослідження проведені на реальному наборі даних Traffic Prediction Dataset з використанням горизонтів прогнозування від 1 до 12 годин, що дозволило дослідити залежність показників точності від горизонту прогнозування. Встановлено, що застосування попередньої обробки вихідних даних забезпечує суттєве зниження середньої абсолютної помилки (MAE) для рекурентних архітектур на 30–37% порівняно з базовими методами.

Проведений порівняльний аналіз моделей короткострокового прогнозування за критеріями точності та швидкості навчання показав, що моделі LSTM та GRU забезпечують найкращу точність на коротких горизонтах (MAPE  $\approx$  8.6%). Водночас архітектура 1D-CNN демонструє у 3.7–4.0 рази вищу швидкість навчання на CPU порівняно з LSTM.

Подальші дослідження можуть бути спрямовані на вдосконалення моделі на основі 1D-CNN шляхом оптимізації архітектурних параметрів та режимів навчання, використання паралельної обробки даних на GPU, а також розширення підходів до попередньої обробки, з метою зменшення похибки при збереженні високої швидкодії.

#### Список використаної літератури

1. Nagy A. M., Simon V. Survey on traffic prediction in smart cities. *Pervasive and Mobile Computing*. 2018. Vol. 50. Pp. 148–163. DOI: 10.1016/j.pmcj.2018.07.004
2. Lana I., Del Ser J., Velez-Langenberg M., Vlahogianni E. I. Road traffic forecasting: Recent advances and new challenges. *IEEE Intelligent Transportation Systems Magazine*. 2018. Vol. 10, no. 2. Pp. 93–109. DOI: 10.1109/ITS.2018.2806634
3. Vlahogianni E. I., Karlaftis M. G., Golias J. C. Short-term traffic forecasting: Where we are and where we're going. *Transportation Research Part C: Emerging Technologies*. 2014. Vol. 43. Pp. 3–19. DOI: 10.1016/j.trc.2014.05.005
4. Ma X., Tao Z., Wang Y., Yu H., Wang Y. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C: Emerging Technologies*. 2015. Vol. 54. Pp. 187–197. DOI: 10.1016/j.trc.2015.03.014
5. Fu R., Zhang Z., Li L. Using LSTM and GRU neural network methods for traffic flow prediction. *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*. Wuhan, China. 2016. Pp. 324–328. DOI: 10.1109/YAC.2016.7804912
6. Jia Y., Cai C., Gorges D. An LSTM-Based Speed Predictor Based on Traffic Simulation Data for Improving the Performance of Energy-Optimal Adaptive Cruise Control *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*. Rhodes, Greece. 2020. Pp. 1–6. DOI: 10.1109/ITSC45102.2020.9294285
7. Wu Y., Tan H., Qin L., Ran B., Jiang Z. A hybrid deep learning based traffic flow prediction method and its understanding. *Transportation Research Part C: Emerging Technologies*. 2018. Vol. 90. Pp. 166–180. DOI: 10.1016/j.trc.2018.03.001
8. Zhang J., Zheng Y., Qi D. Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction. *Thirty-First AAAI Conference on Artificial Intelligence*. San Francisco, USA. 2017. Pp. 1655–1661. DOI: 10.1609/aaai.v31i1.10735
9. Manibardo E., Lana I., Del Ser J. Deep Learning for Road Traffic Forecasting: Does it Make a Difference? *IEEE Transactions on Intelligent Transportation Systems*. 2022. Vol. 23, no. 6. Pp. 6164–6188. DOI: 10.1109/TITS.2021.3083957
10. Wu Z., Pan S., Long G., Jiang J., Zhang C. Graph WaveNet for Deep Spatial-Temporal Graph Modeling. *Proceedings of the 28th International Joint Conference on Artificial Intelligence (IJCAI)*. Macao, China. 2019. Pp. 1907–1913. DOI: 10.24963/ijcai.2019/264
11. Song Y., Zhang Y., Liu X. Convolutional Neural Network-Based Bidirectional Gated Recurrent Unit-Additive Attention Mechanism Hybrid Deep Neural Networks for Short-Term Traffic Flow Prediction. *Sustainability*. 2024. Vol. 16, no. 3. Pp. 1–15. DOI: 10.3390/su16051986
12. Aburasain R. Y. Enhanced congestion prediction of traffic flow using a hybrid attention-based deep learning model. *PeerJ Computer Science*. 2025. Vol. 11. Pp. 1–23. DOI: 10.7717/peerj-cs.3224

## References

1. Nagy, A. M., Simon, V. (2018). Survey on traffic prediction in smart cities. *Pervasive and Mobile Computing*. Vol. 50. Pp. 148–163. DOI: 10.1016/j.pmcj.2018.07.004
2. Lana, I., Del Ser, J., Velez-Langenberg, M., Vlahogianni, E. I. (2018). Road traffic forecasting: Recent advances and new challenges. *IEEE Intelligent Transportation Systems Magazine*. Vol. 10, no. 2. Pp. 93–109. DOI: 10.1109/MITS.2018.2806634
3. Vlahogianni, E. I., Karlaftis, M. G., Golias, J. C. (2014). Short-term traffic forecasting: Where we are and where we're going. *Transportation Research Part C: Emerging Technologies*. Vol. 43. Pp. 3–19. DOI: 10.1016/j.trc.2014.05.005
4. Ma, X., Tao, Z., Wang, Y., Yu, H., Wang, Y. (2015). Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C: Emerging Technologies*. Vol. 54. Pp. 187–197. DOI: 10.1016/j.trc.2015.03.014
5. Fu, R., Zhang, Z., Li, L. (2016). Using LSTM and GRU neural network methods for traffic flow prediction. *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*. Wuhan, China. Pp. 324–328. DOI: 10.1109/YAC.2016.7503671
6. Jia, Y., Cai, C., Görges, D. (2020). An LSTM-Based Speed Predictor Based on Traffic Simulation Data for Improving the Performance of Energy-Optimal Adaptive Cruise Control *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*. Rhodes, Greece. Pp. 1–6. DOI: 10.1109/ITSC45102.2020.9294285
7. Wu, Y., Tan, H., Qin, L., Ran, B., Jiang, Z. (2018). A hybrid deep learning based traffic flow prediction method and its understanding. *Transportation Research Part C: Emerging Technologies*. Vol. 90. Pp. 166–180. DOI: 10.1016/j.trc.2018.03.001
8. Zhang, J., Zheng, Y., Qi, D. (2017). Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction. *Thirty-First AAAI Conference on Artificial Intelligence*. San Francisco, USA. Pp. 1655–1661. DOI: 10.1609/aaai.v31i1.10735
9. Manibardo, E., Lana, I., Del Ser, J. (2022). Deep Learning for Road Traffic Forecasting: Does it Make a Difference? *IEEE Transactions on Intelligent Transportation Systems*. Vol. 23, no. 6. Pp. 6164–6188. DOI: 10.1109/TITS.2021.3083957
10. Wu, Z., Pan, S., Long, G., Jiang, J., Zhang, C. (2019). Graph WaveNet for Deep Spatial-Temporal Graph Modeling. *Proceedings of the 28th International Joint Conference on Artificial Intelligence (IJCAI)*. Macao, China. Pp. 1907–1913. DOI: 10.24963/ijcai.2019/264
11. Song, Y., Zhang, Y., Liu, X. (2024). Convolutional Neural Network-Based Bidirectional Gated Recurrent Unit-Additive Attention Mechanism Hybrid Deep Neural Networks for Short-Term Traffic Flow Prediction. *Sustainability*. Vol. 16, no. 3. 1205. DOI: 10.3390/su16031205
12. Aburasain, R. Y. (2025). Enhanced congestion prediction of traffic flow using a hybrid attention-based deep learning model. *PeerJ Computer Science*. Vol. 11. Pp. 1–23. DOI: 10.7717/peerj-cs.3224

Дата першого надходження статті до видання: 14.02.2026

Дата прийняття статті до друку після рецензування: 20.03.2026

Дата публікації (оприлюднення) статті: 07.05.2026