

<https://doi.org/10.31891/2307-5732-2026-363-5>

УДК 004.9

ДОХНЯК БОГДАН

Національний університет «Львівська політехніка»

<https://orcid.org/0000-0003-4911-8950>

e-mail: bohdan-oleksandr.o.dokhniak@lpnu.ua

ХАВАЛКО ВІКТОР

Національний університет «Львівська політехніка»

<https://orcid.org/0000-0002-9585-3078>

e-mail: viktor.m.khavalko@lpnu.ua

ДОСЛІДЖЕННЯ СІМЕЙ МЕТОДІВ ДЛЯ ПРОГНОЗУВАННЯ ЗАГРУЖЕНОСТІ ТРАНСПОРТНОЇ МЕРЕЖІ

У роботі проведено комплексне дослідження та систематизацію сімей методів прогнозування завантаженості транспортних мереж, що є критично важливим компонентом сучасних інтелектуальних транспортних систем. Актуальність теми зумовлена стрімкою урбанізацією та необхідністю ефективного керування транспортними потоками для зменшення заторів і підвищення безпеки руху.

У статті виконано порівняльний аналіз трьох основних класів підходів: параметричних статистичних моделей, методів машинного навчання та глибокого навчання. Показано, що традиційні методи, такі як ARIMA та фільтр Калмана, хоча і є ефективними для короткострокових прогнозів на окремих ділянках, мають обмежені можливості у моделюванні нелінійних просторово-часових залежностей складних мереж. Методи машинного навчання, зокрема метод опорних векторів та випадковий ліс (Random Forest), демонструють вищу гнучкість, проте часто потребують складного ручного конструювання ознак.

Особливу увагу приділено сімейству методів глибокого навчання, зокрема рекурентним та згортковим нейронним мережам, а також їхній еволюції у графові нейронні мережі. Детально проаналізовано архітектури, які моделюють транспортний потік як процес дифузії на орієнтованому графі, що дозволяє ефективно враховувати топологію дорожньої мережі та просторові кореляції. Дослідження також висвітлює новітні гібридні та ансамблеві підходи. Розглянуто модель, яка інтегрує дані навігаційних систем про майбутні наміри водіїв через спеціалізований трансформер домену, підвищуючи точність прогнозування нерегулярних заторів. Також проаналізовано ефективність методів ансамблювання що комбінують різномірні базові моделі для підвищення робастності та точності прогнозу.

Зроблено висновок, що найбільш перспективним напрямком є розробка гібридних моделей, які поєднують здатність GNN до просторового моделювання з механізмами уваги та інтеграцією зовнішніх контекстних даних.

Ключові слова: прогнозування транспортних потоків, інтелектуальні транспортні системи, графові нейронні мережі, глибоке навчання, ансамблеві методи, просторово-часовий аналіз.

DOHNYAK BOHDAN, HAVALKO VIKTOR

National University "Lviv Polytechnic"

RESEARCH OF FAMILIES OF METHODS FOR FORECASTING TRANSPORT NETWORK CONGESTION

The paper conducts a comprehensive investigation and systematization of method families for predicting traffic network congestion, a critical component of modern Intelligent Transportation Systems (ITS). The relevance of this topic is driven by rapid urbanization and the need for efficient traffic flow management to reduce congestion and improve safety.

The study performs a comparative analysis of three main classes of approaches: parametric statistical models, Machine Learning (ML), and Deep Learning (DL). It demonstrates that traditional methods like ARIMA and Kalman Filtering, while effective for short-term predictions on isolated segments, are limited in modeling nonlinear spatiotemporal dependencies of complex networks. ML methods, such as Support Vector Machines (SVM) and Random Forests, show greater flexibility but often require complex feature engineering.

Special attention is given to the deep learning family, particularly Recurrent (RNN, LSTM) and Convolutional Neural Networks (CNN), and their evolution into Graph Neural Networks (GNN). The paper details architectures like DCRNN (Diffusion Convolutional Recurrent Neural Network) and STGCN, which model traffic flow as a diffusion process on a directed graph, effectively capturing road network topology and spatial correlations.

The research also highlights emerging hybrid and ensemble approaches. It reviews the H-STGCN model, which integrates navigation data regarding future driver intentions via a specialized domain transformer, improving the prediction of non-recurring congestion. The effectiveness of ensemble methods (Stacking), which combine diverse base learners (e.g., MLP and SVC) to enhance robustness and accuracy, is also analyzed.

It is concluded that the most promising direction involves developing hybrid models that combine the spatial modeling capabilities of GNNs with attention mechanisms and the integration of external contextual data.

Keywords: traffic flow prediction, Intelligent Transportation Systems, Graph Neural Networks, Deep Learning, ensemble methods, spatiotemporal analysis.

Стаття надійшла до редакції / Received 08.01.20265

Прийнята до друку / Accepted 11.02.2026

Опубліковано / Published 26.03.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© Дохняк Богдан, Хавалко Віктор

Постановка проблеми у загальному вигляді та її зв'язок із важливими науковими чи практичними завданнями

Стрімка урбанізація та зростання чисельності населення призвели до безпрецедентного збільшення попиту на мобільність, що спричинило перевантаження транспортних мереж у великих містах. Це явище породжує комплекс соціальних, економічних та екологічних проблем: від втрати часу в заторах та зниження продуктивності праці до збільшення споживання палива, зростання рівня забруднення повітря та підвищення аварійності на дорогах.

Ключовою проблемою є нездатність наявної транспортної інфраструктури адаптуватися до динамічних змін трафіку в реальному часі. Традиційні підходи до розширення інфраструктури мають фізичні та фінансові обмеження, тому акцент зміщується на ефективне управління транспортними потоками за допомогою Інтелектуальних транспортних систем (ITS). Фундаментальним компонентом ITS є підсистема прогнозування, здатна точно передбачати стан мережі (швидкість, обсяг потоку, час у дорозі) для прийняття проактивних управлінських рішень. Однак точне прогнозування трафіку залишається складною проблемою через стохастичну та нелінійну природу транспортних потоків, на які впливають численні зовнішні фактори (погода, аварії, масові заходи). Історичні параметричні методи (наприклад, ARIMA) та прості моделі машинного навчання часто не можуть адекватно моделювати ці складні залежності, оскільки спираються на припущення про стаціонарність даних, що часто порушується в реальних умовах. З наукової точки зору, проблема інтелектуального аналізу транспортних мереж пов'язана з необхідністю розробки нових математичних моделей та алгоритмів, здатних обробляти складні просторово-часові дані.

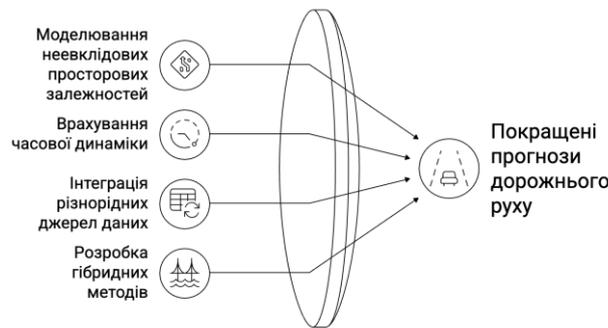


Рис. 1 Зв'язок із важливими науковими завданнями



Рис. 2 Зв'язок із практичними завданнями

Основними науковими завданнями є:

- **Моделювання неевклідових просторових залежностей:** Дорожні мережі мають структуру графів, а не регулярних сіток (як зображення). Тому класичні згорткові нейронні мережі (CNN) є менш ефективними. Виникає необхідність розробки та вдосконалення графових нейронних мереж (GNN), які можуть враховувати топологію мережі та напрямок руху.
- **Враховування часової динаміки та довгострокових залежностей:** Транспортні дані мають складні часові патерни (добова, тижнева сезонність), які змінюються під впливом випадкових подій. Науковим викликом є створення архітектур (наприклад, на базі LSTM, GRU або механізмів уваги), які можуть утримувати інформацію про довготривалі залежності та адаптуватися до нестационарності.
- **Інтеграція різномірних джерел даних (Data Fusion):** Підвищення точності прогнозу вимагає об'єднання даних з різних джерел: індуктивних петель, GPS-треків (Floating Car Data), навігаційних систем про наміри водіїв, а також контекстної інформації (погода, календарі подій).
- **Розробка гібридних та ансамблевих методів:** Для подолання обмежень окремих алгоритмів (наприклад, зміщення або високої дисперсії) актуальним є завдання створення ансамблевих моделей (Stacking, Boosting), які комбінують переваги глибокого навчання та класичних алгоритмів для підвищення якості прогнозу.
- **Оптимізація управління трафіком:** Точні прогнози дозволяють впроваджувати адаптивне керування світлофорами, динамічний розподіл смуг руху та попереджувати виникнення заторів ще до їх формування.

- Планування маршрутів та навігація: Для індивідуальних користувачів та логістичних компаній критично важливою є точна оцінка часу прибуття (ETA) та вибір оптимального маршруту з урахуванням майбутнього стану мережі.
- Підтримка автономних транспортних засобів: Ефективна робота безпілотного транспорту неможлива без надійного прогнозування поведінки навколишнього трафіку та стану дорожньої мережі.
- Екологічна безпека та енергоефективність: Зменшення часу простою в заторах безпосередньо корелює зі зменшенням викидів вуглецю та економією палива, що є пріоритетом для сталого розвитку міст.

Аналіз досліджень та публікацій

Проблема прогнозування завантаженості транспортних мереж є предметом активних наукових пошуків протягом останніх десятиліть. Еволюція підходів у цій сфері пройшла шлях від класичних статистичних моделей до складних архітектур глибокого навчання, здатних обробляти великі обсяги просторово-часових даних.

Класичні параметричні та непараметричні підходи. На ранніх етапах розвитку інтелектуальних транспортних систем (ITS) домінуючими були параметричні моделі, засновані на аналізі часових рядів. Зокрема, модель авторегресії з інтегрованим ковзним середнім (ARIMA) та її варіації (SARIMA) стали стандартом для короткострокового прогнозування[1,2]. Також широко застосовувалися методи фільтрації Калмана для мінімізації дисперсії та вирішення задач регресії. Головним недоліком цих методів є опора на припущення про стаціонарність даних, що часто порушується в реальних умовах через стохастичну природу дорожнього руху. Для подолання обмежень лінійних моделей дослідники звернулися до непараметричних методів машинного навчання (ML), таких як метод опорних векторів (SVR), k-найближчих сусідів (KNN) та випадковий ліс (Random Forest)[1,3]. Наприклад, у роботах, показано, що алгоритм опорних векторів дозволяє ефективно будувати розділові гіперплощини для задач класифікації та регресії. Проте, традиційні ML-алгоритми часто розглядають дорожні сегменти ізольовано або вимагають складного ручного конструювання ознак, ігноруючи топологічну структуру транспортної мережі.

Методи глибокого навчання: від послідовностей до зображень. З появою великих даних (Big Data) акцент змістився на методи глибокого навчання (DL). Для моделювання часових залежностей широко використовуються рекурентні нейронні мережі (RNN), зокрема мережі довгої короткочасної пам'яті (LSTM) та керовані рекурентні блоки (GRU), які вирішують проблему зникаючого градієнта[1,2].

Спроби врахувати просторову складову призвели до застосування згорткових нейронних мереж (CNN), де транспортна мережа представлялася у вигляді регулярної сітки (grid-based approach). Однак, як зазначається в[2,4], дорожні мережі мають структуру графа, а не евклідового простору, тому застосування стандартних CNN призводить до втрати інформації про реальну топологію зв'язків. Графові нейронні мережі (GNN). Проривним напрямком стало використання графових нейронних мереж, які моделюють транспортну мережу як орієнтований або неорієнтований граф.

Спектральні та просторові підходи: У роботі описується модель STGCN (Spatio-Temporal Graph Convolutional Networks), яка комбінує спектральні графові згортки для простору та одновимірні CNN для часу[2].

Дифузійні згорткові мережі (DCRNN): Автори запропонували моделювати трафік як дифузійний процес на орієнтованому графі. Використання двонаправлених випадкових блукань (random walks) та архітектури Encoder-Decoder дозволило досягти значного покращення точності (на 12-15%) порівняно з базовими методами[4].

Механізми уваги: Розвиток GNN призвів до появи моделей з механізмом уваги (Graph Attention Networks — GAT), які дозволяють динамічно визначати вагу впливу сусідніх вузлів, фокусуючись на найбільш значущих зв'язках.

Гібридні архітектури та ансамблеві методи. Сучасні дослідження спрямовані на підвищення робастності моделей шляхом інтеграції різнорідних даних та комбінування алгоритмів.

Інтеграція навігаційних даних: У роботі запропоновано гібридну модель H-STGCN, яка використовує дані про наміри водіїв (intended traffic volume) з навігаційних систем. Автори розробили спеціальний трансформер домену для конвертації обсягу трафіку в еквівалент часу проїзду та запропонували використовувати компаундну матрицю суміжності, що враховує коваріацію часових рядів. Це дозволяє краще прогнозувати нерегулярні затори (non-recurring congestion)[5].

Ансамблеве навчання (Ensemble Learning): Дослідження демонструє ефективність методів стекинг (Stacking). Комбінація базових моделей, таких як багатошаровий перцептрон (MLP) та класифікатор опорних векторів (SVC), з використанням логістичної регресії як мета-моделі, дозволяє зменшити дисперсію помилки та підвищити точність класифікації станів заторів[3].

Формулювання цілей статті

Метою роботи є: підвищення точності та надійності прогнозування завантаженості транспортних мереж шляхом систематизації, критичного аналізу та визначення меж застосування основних сімей методів: від класичних статистичних моделей до новітніх архітектур на основі графових нейронних мереж (GNN) та ансамблевого навчання.

Для реалізації поставленої мети в роботі розв'язується комплекс взаємопов'язаних завдань. Передусім, дослідження передбачає глибоку класифікацію та порівняльний аналіз традиційних параметричних підходів і методів машинного навчання, що дозволяє чітко окреслити межі їхньої ефективності при короткостроковому прогнозуванні та роботі з нелінійними залежностями. Логічним продовженням цього аналізу є дослідження еволюції методів глибокого навчання: від класичного моделювання часових рядів та використання згорток на

регулярних сітках до переходу на графові нейронні мережі, які здатні коректно враховувати специфічну неевклідову топологію дорожньої інфраструктури.

В цьому контексті особлива увага приділяється вивченню ефективності сучасних архітектур просторово-часового моделювання, таких як DCRNN та STGCN, зокрема їхній здатності розглядати трафік як дифузійний процес та виявляти приховані залежності навіть між віддаленими сегментами мережі. Разом із тим, оцінюється потенціал гібридних та ансамблевих підходів, які через інтеграцію різнорідних даних — наприклад, навігаційної інформації чи погодних умов — забезпечують високу робастність моделей в умовах концептуального дрейфу даних та нерегулярних заторів. Фінальним етапом роботи є визначення перспективних векторів подальших наукових розвідок, із фокусом на проблемах інтеграції зовнішніх контекстних факторів та розробці адаптивних матриць суміжності для динамічних транспортних графів.

Виклад основного матеріалу

Дослідження сімей методів прогнозування завантаженості транспортної мережі вимагає формалізації задачі як проблеми просторово-часового моделювання на графах. Транспортна мережа представляється у вигляді зваженого орієнтованого графа $G=(V, E, W)$, де V — множина вузлів, E — множина ребер, а $W \in \mathbb{R}^{N \times N}$ — матриця суміжності, що відображає топологічну або семантичну близькість вузлів.

Нехай $X_t \in \mathbb{R}^{N \times P}$ - сигнал графа (матриця ознак, наприклад, швидкість та інтенсивність потоку) у момент часу t . Завдання полягає у навчанні функції f , яка відображає історичну послідовність T' спостережень у прогноз на T кроків у майбутнє з :

$$[X_{t-T'+1}, \dots, X_t; G] \xrightarrow{f(\cdot)} [X_{t+1}, \dots, X_{t+T}]$$

У роботі виділено та систематизовано три ключові сім'ї методів, що демонструють еволюцію підходів від статистичного навчання до гібридних нейромережових архітектур. Сім'я методів машинного навчання та ансамблеві підходи (ML & Ensemble Methods). Ця сім'я методів відмовляється від жорстких припущень про стаціонарність даних, властивих класичним параметричним моделям (ARIMA, фільтр Калмана). Ключовим напрямком тут є використання ансамблевих технік, які комбінують кілька базових моделей для зменшення дисперсії помилки та підвищення узагальнюючої здатності.

Особливу ефективність демонструє метод стекінгу (Stacking). У цій архітектурі прогнози різнорідних базових моделей (Base Learners), таких як багатошаровий перцептрон (MLP) та метод опорних векторів (SVC), використовуються як вхідні ознаки для мета-моделі (Meta-Learner), наприклад, логістичної регресії. Математично фінальний прогноз моделі можна виразити як зважену комбінацію[3]:

$$FPM(t) = \sum_{k=1}^K w_k \alpha_k(t)$$

де $\alpha_k(t)$ - прогноз k -ї базової моделі, а w_k - вага, що визначається мета-алгоритмом. Такий підхід дозволяє компенсувати слабкі сторони окремих алгоритмів (наприклад, схильність MLP до перенавчання на малих вибірках) і досягати точності до 93.2% у задачах класифікації рівнів заторів[3].

Також до цієї сім'ї належать методи градієнтного бустінгу (XGBoost, LightGBM), які послідовно будують дерева рішень, виправляючи помилки попередніх ітерацій. LightGBM, зокрема, використовує алгоритм навчання на основі гістограм, що забезпечує високу швидкість обробки великих масивів даних. Сім'я Графових нейронних мереж (Spatio-Temporal GNN). Це найбільш прогресивна сім'я методів, яка вирішує фундаментальну проблему згорткових мереж (CNN) - неможливість адекватної роботи з неевклідовими структурами даних. У ході дослідження виділено два основні підходи до реалізації згортки на графі:

Спектральний підхід (Spectral GCN). Базується на спектральній теорії графів. Згортка визначається в області Фур'є через розкладання лапласіана графа $L = I_n - D^{-1/2} W D^{-1/2}$. Для уникнення високої обчислювальної складності ($O(N^3)$) використовуються поліноми Чебишева $T_k(x)$ для апроксимації фільтрів (моделі ChebNet, STGCN) в. Формула згортки сигналу x з фільтром g_θ :

$$x \star g_\theta \approx \sum_{k=0}^{K-1} \theta_k T_k(\tilde{L})x$$

де \tilde{L} - масштабований лапласіан. Цей метод ефективно локалізує ознаки, проте вимагає, щоб граф був незмінним (статичним).

Просторовий (Дифузійний) підхід (Diffusion GCN). Яскравим представником є архітектура DCRNN (Diffusion Convolutional Recurrent Neural Network). Тут динаміка трафіку моделюється як процес дифузії сигналів між вузлами. Ключовою особливістю є використання двонаправлених випадкових блукань (bidirectional random walks), що дозволяє враховувати асиметричний вплив висхідних (upstream) та низхідних (downstream) потоків. Операція дифузійної згортки визначається як:

$$X_{:,p} \star_G f_\theta = \sum_{k=0}^{K-1} (\theta_{k,1} (D_0^{-1} W)^k + \theta_{k,2} (D_I^{-1} W^T)^k) X_{:,p}$$

де $D_0^{-1} W$ та $D_I^{-1} W^T$ - матриці ймовірностей переходів[4]. Інтеграція цієї згортки в рекурентний блок GRU (DCGRU) та використання механізму Scheduled Sampling (поступовий перехід від навчання на реальних даних до навчання на власних прогнозах) дозволяє моделі ефективно захоплювати довгострокові часові залежності.

Сім'я гібридних та контекстно-орієнтованих архітектур. Ця сім'я методів спрямована на подолання обмежень, пов'язаних із "сліпотою" моделей до зовнішнього контексту (подій, намірів водіїв).

Модель H-STGCN (Hybrid Spatio-Temporal GCN). Інновацією цього підходу є використання даних про наміри водіїв (intended traffic volume) з навігаційних систем. Оскільки ці дані є гетерогенними щодо основного сигналу (часу в дорозі), застосовується спеціалізований Трансформер домену[5].

Крім того, в рамках цієї сім'ї пропонується вдосконалення матриці суміжності. Замість статичної матриці відстаней $W^{(d)}$, використовується компаундна матриця (Compound Adjacency Matrix) $W^{(c)}$, яка поєднує фізичну відстань та коваріацію часових рядів σ_{ij} :

$$w_{ij}^{(c)} = \sigma_{ij} \cdot w_{ij}^{(d)}$$

Це дозволяє моделювати "приховані" зв'язки між дорогами, які не є фізично сусідами, але мають синхронізовану динаміку трафіку (наприклад, паралельні вулиці). Проведений аналіз показує чітку ієрархію методів: від статистичних моделей, що працюють з одновимірними часовими рядами, до ансамблевих методів, що підвищують робастність, і, нарешті, до графових архітектур (GNN), які безпосередньо моделюють топологію мережі. Найбільш перспективним напрямком є гібридизація GNN з механізмами уваги та інтеграцією даних про майбутній попит (навігаційні дані), що дозволяє перейти від реактивного до проактивного прогнозування.

Висновки з даного дослідження

і перспективи подальших розвідок у даному напрямі

Узагальнюючи результати проведеного дослідження сімей методів прогнозування, стає очевидним, що ця предметна область пройшла значний еволюційний шлях від лінійності до глибокої структурної складності. Традиційні параметричні моделі на кшталт ARIMA чи класичні алгоритми машинного навчання, хоч і залишаються необхідними бенчмарками, фактично вичерпали свій ресурс для задач сучасного мегаполіса, оскільки не здатні ефективно схопити високодинамічні нелінійні процеси. Справжнім проривом стала зміна парадигми сприйняття даних: перехід від розгляду трафіку як зображення до його інтерпретації у вигляді графів, що набагато краще відповідає неевклідовій топології доріг. Графові нейронні мережі, зокрема архітектури типу DCRNN, довели свою перевагу, забезпечуючи суттєвий приріст точності завдяки моделюванню дифузії трафіку та врахуванню двонаправлених потоків. При цьому сучасний "state-of-the-art" формується вже не окремими алгоритмами, а складними гібридними системами, де ансамблеві методи (такі як стекінг) компенсують недоліки слабких класифікаторів, а механізми уваги дозволяють знаходити приховані семантичні зв'язки між ділянками мережі, які навіть не є прямими сусідами. Інтеграція ж даних про навігаційні наміри водіїв дозволяє таким системам працювати на випередження, прогнозуючи затори ще до їх фізичного виникнення.

Аналіз існуючих обмежень дозволяє чітко окреслити вектор подальших наукових пошуків, який зміщується в бік мультимодальності та адаптивності. Критично важливим напрямком стає розширення вхідних даних за рахунок екзогенних факторів — погоди, масових заходів чи активності в соціальних мережах, що вимагатиме нових підходів до злиття різномірної інформації. Крім того, оскільки міський трафік змінюється в часі, статичні матриці суміжності стають рудиментом; майбутнє за динамічними графовими мережами, які здатні адаптувати структуру зв'язків у реальному часі. Разом із ускладненням архітектур ("black box") гостро постає питання інтерпретованості рішень штучного інтелекту для операторів ITS, а також забезпечення кіберстійкості систем, що спираються на вразливі IoT-сенсори. У довгостроковій перспективі метою цих досліджень є перехід від пасивного прогнозування до активного керування містом, де прогнозні моделі у поєднанні з навчанням з підкріпленням безпосередньо оптимізуватимуть роботу світлофорів та маршрутизацію.

Література

1. Sayed S. A. Artificial intelligence-based traffic flow prediction: a comprehensive review / S. A. Sayed, Y. Abdel-Hamid, H. A. Hefny // *Journal of Electrical Systems and Information Technology*. – 2023. – Vol. 10, № 13. – P. 1–25.
2. Li Y. Diffusion Convolutional Recurrent Neural Network: Data-Driven Traffic Forecasting / Y. Li, R. Yu, C. Shahabi, Y. Liu // *International Conference on Learning Representations (ICLR)*. – 2018. – P. 1–16.
3. Rico J. Graph Neural Networks for Traffic Forecasting / J. Rico, J. Barateiro, A. Oliveira // *arXiv preprint arXiv:1906.02706*. – 2021.
4. Dai R. Hybrid Spatio-Temporal Graph Convolutional Network: Improving Traffic Prediction with Navigation Data / R. Dai, S. Xu, Q. Gu, C. Ji, K. Liu // *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. – 2020. – P. 3074–3082.
5. Bhatele M. Integrating Deep Learning And Ensemble Methods For Urban Traffic Forecasting / M. Bhatele, P. Bhartiya, A. A. Wao // *International Journal of Environmental Sciences*. – 2025. – Vol. 11, № 8s. – P. 565–582.

References

1. Sayed S. A. Artificial intelligence-based traffic flow prediction: a comprehensive review / S. A. Sayed, Y. Abdel-Hamid, H. A. Hefny // *Journal of Electrical Systems and Information Technology*. – 2023. – Vol. 10, № 13. – P. 1–25.
2. Li Y. Diffusion Convolutional Recurrent Neural Network: Data-Driven Traffic Forecasting / Y. Li, R. Yu, C. Shahabi, Y. Liu // *International Conference on Learning Representations (ICLR)*. – 2018. – P. 1–16.
3. Rico J. Graph Neural Networks for Traffic Forecasting / J. Rico, J. Barateiro, A. Oliveira // *arXiv preprint arXiv:1906.02706*. – 2021.
4. Dai R. Hybrid Spatio-Temporal Graph Convolutional Network: Improving Traffic Prediction with Navigation Data / R. Dai, S. Xu, Q. Gu, C. Ji, K. Liu // *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. – 2020. – P. 3074–3082.
5. Bhatele M. Integrating Deep Learning And Ensemble Methods For Urban Traffic Forecasting / M. Bhatele, P. Bhartiya, A. A. Wao // *International Journal of Environmental Sciences*. – 2025. – Vol. 11, № 8s. – P. 565–582.