
Застосування графових нейронних мереж для аналізу транспортних маршрутів

Олена Доля

Кафедра інформаційних управляючих систем, Харківський національний університет радіоелектроніки, Україна

ORCID: 0000-0002-0364-988X

Анотація: метою статті є обґрунтування та практична перевірка підходу до аналізу транспортних маршрутів на основі графових нейронних мереж у задачах короткострокового прогнозування стану міської мережі. У фокусі дослідження — підвищення точності передбачення часу проходження маршрутів, раннє виявлення потенційно перевантажених ділянок і підтримка оперативних рішень диспетчерського управління. Додатковою метою є оцінювання придатності сучасних просторово-часових архітектур до роботи в умовах нестаціонарного попиту, часткової неповноти даних та впливу зовнішніх факторів (погода, інциденти, календарні піки).

У роботі транспортну систему подано як орієнтований зважений граф, у якому вузли відповідають ключовим елементам інфраструктури, а ребра — можливим напрямом руху. Сформовано постановку задачі прогнозування для часових горизонтів 15–60 хвилин, визначено вхідні ознаки та цільові метрики якості (MAE, RMSE, MAPE). Виконано порівняльний аналіз сучасних підходів (DCRNN, T-GCN, Graph WaveNet та ін.) і обрано модель з адаптивною матрицею суміжності та механізмом часової уваги. Проведено обчислювальний експеримент на синтетично-реалістичному наборі даних міської мережі, включно зі сценарієм «ранковий пік + інцидент». Отримані результати продемонстрували вищу точність обраного підходу порівняно з базовими моделями, а також кращу стійкість до шумів і пропусків у телеметрії.

За підсумками дослідження встановлено, що графові нейронні мережі є ефективним інструментом для практичних задач транспортної аналітики та прогнозного керування маршрутами. Запропонований підхід забезпечує кращу узгодженість прогнозів на довших горизонтах, дозволяє своєчасно ідентифікувати критичні ділянки мережі та формувати обґрунтовані керуючі дії. Практична цінність результатів полягає у можливості їх інтеграції в підсистеми підтримки рішень для зниження затримок, підвищення надійності перевезень і покращення якості транспортного обслуговування..

Ключові слова: графові нейронні мережі; транспортні маршрути; просторово-часове прогнозування; графове моделювання; інтелектуальні транспортні системи; керування трафіком.

1. Вступ

Транспортна інфраструктура сучасних міст і регіонів є складною динамічною системою, у межах якої щоденно відбувається велика кількість взаємопов'язаних процесів: формування попиту на перевезення, перерозподіл транспортних потоків, зміна швидкості руху на окремих ділянках мережі, виникнення локальних перевантажень та затримок. В умовах зростання урбанізації, підвищення мобільності населення і збільшення щільності транспортних засобів традиційні підходи до аналізу маршрутів, що базуються переважно на спрощених статистичних моделях або локальних евристичних, дедалі частіше демонструють обмежену точність і недостатню адаптивність до швидких змін дорожньої ситуації.

Однією з ключових причин цієї проблеми є те, що транспортна мережа має виражену графову природу: зупинки, перехрестя, станції та логістичні вузли можуть бути представлені як вершини, а дорожні або рейкові сполучення між ними — як ребра з вагами, що змінюються в часі. Відтак для коректного моделювання необхідно одночасно враховувати як топологічну структуру мережі, так і часову динаміку її станів. Саме тому останніми роками значну увагу дослідників привертають графові нейронні мережі (Graph Neural Networks, GNN), які забезпечують можливість навчання на структурованих графових даних та виявлення прихованих просторовочасових залежностей між елементами транспортної системи.

Перевага GNN-підходів полягає у здатності узагальнювати інформацію від сусідніх вузлів, формувати контекстно-залежні подання та враховувати нелінійний характер взаємодій у мережі. Для задач аналізу транспортних маршрутів це відкриває можливості більш точного прогнозування часу поїздки, раннього виявлення потенційно проблемних ділянок, оцінювання стійкості маршрутної мережі до пікових навантажень і підтримки рішень щодо оптимізації руху. Практична цінність таких результатів полягає не лише у підвищенні ефективності перевезень, а й у зменшенні економічних втрат від заторів, покращенні екологічних показників та підвищенні якості транспортного обслуговування населення.

Попри значний прогрес у застосуванні глибокого навчання до транспортних задач, залишаються відкритими питання вибору оптимальної архітектури моделі, способу побудови графа для різних типів транспортних систем, інтерпретованості отриманих прогнозів і забезпечення стійкості моделей до шумів та пропусків у даних. У зв'язку з цим актуальним є подальше дослідження методів графового машинного навчання для комплексного аналізу маршрутів у реальних умовах експлуатації транспортної мережі.

2. Об'єкт і предмет дослідження

Об'єкт дослідження — процеси формування, перерозподілу та часової зміни транспортних потоків у міській маршрутній мережі, що функціонує в умовах нерівномірного попиту, впливу зовнішніх факторів і обмеженої пропускної здатності окремих ділянок.

Предмет дослідження — методи просторово-часового моделювання і прогнозування характеристик маршрутів (швидкість руху, інтенсивність потоку, час проходження) на основі графових нейронних мереж з механізмами уваги та адаптивним врахуванням топології мережі.

3. Аналіз літератури

У науковій літературі останніх років простежується стійкий перехід від класичних статистичних моделей прогнозування транспортних потоків до методів глибокого навчання на графах. Теоретичну основу цього переходу сформовано в узагальнювальних працях, присвячених архітектурам графових нейронних мереж, їхнім механізмам агрегації та основним сферам застосування [1, 2]. Концептуально важливим кроком стала модель графових згорток для напівконтрольованого навчання [3], яка фактично заклала підґрунтя для подальшого розвитку просторово-структурного аналізу в транспортних задачах. Саме ці дослідження показали, що врахування топології мережі як графа дає принципово нову якість прогнозу порівняно з підходами, що оперують лише часовими рядами.

Першою хвилею прикладних транспортних рішень стали моделі, у яких графова структура поєднувалася з рекурентною часовою динамікою. До таких належить DCRNN [4], де дифузійні згортки застосовуються для врахування напрямлених зв'язків між вузлами транспортної мережі. У цій архітектурі добре опрацьовано проблему просторового перенесення впливу між сусідніми та віддаленими ділянками, що є критично важливим при оцінюванні ефекту заторів. Іншу лінію розвитку презентує STGCN [5], де рекурентні блоки замінено на повністю згортковий просторовочасовий конвеєр. Перевагою цього підходу стала вища обчислювальна ефективність і стабільність навчання на великих масивах міських даних.

Наступний етап розвитку пов'язаний із впровадженням механізмів уваги та адаптивного структурування графа. У моделі ASTGCN [6] автори поєднали просторову і часову увагу, що дозволило краще враховувати різні ритми транспортної активності (пікові та міжпікові періоди, будні та вихідні). Graph WaveNet [7] запропонувала адаптивну матрицю суміжності, яка формується під час навчання та здатна відображати приховані функціональні зв'язки між ділянками мережі, що не завжди очевидні з географічної близькості. У роботі T-GCN [8] графові згортки об'єднано з механізмами послідовнісного моделювання, що дало добрі результати для нестабільних міських потоків. Модель GMAN [9] розширила цей підхід через багаторівневу увагу до просторових і часових залежностей, а STSGCN [10] акцентувала на синхронному моделюванні локальних просторово-часових підграфів.

Паралельно з розвитком базових GNN-архітектур активно досліджувалися гібридні й прикладні рішення для конкретних типів транспортних систем. Узагальнювальний огляд методів прогнозування на основі GNN [11] засвідчує, що найкращі практичні результати досягаються завдяки поєднанню графової обробки з механізмами уваги, багатофакторними ознаками та адаптивними стратегіями навчання. У GECRAN [12] реалізовано комбінацію згорткових, рекурентних і attention-компонентів, що покращує роботу за умов шумних вхідних даних. У межах лінії досліджень короткострокового прогнозування швидкості/інтенсивності руху запропоновано низку гібридних моделей з LSTM, BiLSTM, CNN та їх ансамблевими модифікаціями [13–19]. Хоч ці підходи не завжди є «чистими» GNN, вони формують важливий фон порівняння і підтверджують, що явне урахування мережевої структури зазвичай дає перевагу над суто часовими моделями.

У роботах останніх років простежується зміщення до більш складних просторово-часових конструкцій. Зокрема, STCGCN [20] і SSTGT [21] використовують розширені механізми обміну інформацією між вузлами з урахуванням довгих залежностей та неоднорідної динаміки. Праця, присвячена flow feedback-прогнозуванню [22], демонструє корисність включення зворотних контурів і візуально-квантифікованих ознак для стабілізації передбачень у реальному часі. Для авіаційного напрямку запропоновано причинно-графовий підхід до прогнозування потоків між аеропортами [23], що є важливим з позиції міжмережевого перенесення методів GNN. У MT-STNet [24] реалізовано багатозадачне навчання, яке дозволяє одночасно прогнозувати кілька характеристик транспортного процесу.

Окремого значення набувають підходи контрастивного та трансферного навчання. У роботі з контрастивним навчанням і адаптивним графовим аугментуванням [25] показано, що коректно сформовані позитивні/негативні пари підвищують узагальнювальну здатність моделей на нових ділянках мережі. Огляд LSTM-орієнтованих методів [26] підкреслює, що навіть за розвитку GNN рекурентні структури залишаються релевантними, особливо в ансамблях. Гібрид ARIMA Conv-LSTM із шаром уваги [27] цікавий тим, що комбінує класичну часову декомпозицію зі сучасними глибокими компонентами, що часто корисно для слабо структурованих даних.

Новітні публікації 2025–2026 років фокусуються на переносимості моделей між різними містами, багатофакторному злитті ознак і підвищенні інтерпретованості. Transfer-aware STGAT [28] демонструє, що врахування доменної різниці між джерелом і цільовою мережею помітно зменшує деградацію якості при трансфері. Для дорожніх мереж США запропоновано модифікацію STGCN з розширеним механізмом уваги [29], яка показує стійкі результати на магістральних коридорах. Модель просторово-часового багатофакторного злиття ознак [30] акцентує, що погодні, календарні та інцидентні параметри істотно впливають на точність. Архітектура TSTAGCN [31] поєднує трендовий аналіз із адаптивною графовою згорткою, а кросдоменна трансформерна ST-модель [32] підкреслює перспективність поєднання GNN і transformer-парадигми для мультисценарного прогнозування.

Отже, аналіз 32 джерел дозволяє виділити кілька сталих тенденцій. По-перше, домінує перехід від статичних графів до адаптивних структур, що навчаються разом із моделлю. По-друге, зростає роль механізмів уваги, контрастивного та трансферного навчання для

підвищення узагальнювальної здатності. По-третє, найкращі результати забезпечують гібридні підходи, які поєднують графове подання мережі з багатофакторними часовими ознаками. Водночас відкритими залишаються питання інтерпретованості, стійкості до пропусків і шумів, а також стандартизації протоколів порівняння моделей. Саме вирішення цих проблем формує наукову нішу даного дослідження та обґрунтовує необхідність подальшого вдосконалення GNN-методів для аналізу транспортних маршрутів.

4. Виклад основного матеріалу

Сучасна транспортна мережа природно подається як орієнтований зважений граф, де вершини відповідають транспортним вузлам (перехрестям, зупинкам, станціям), а ребра — можливим напрямкам руху між ними. Такий опис дає змогу одночасно враховувати локальні залежності (сусідні ділянки) і глобальні ефекти (каскадні затримки у віддалених частинах мережі). У прикладних задачах управління важливо не лише фіксувати поточний стан мережі, а й прогнозувати її поведінку на горизонті від кількох хвилин до години, оскільки саме це визначає якість диспетчерських рішень, переналаштування маршрутів та попередження перевантажень. Припустимо транспортна мережа задана графом, як зазначено в (1):

$$G = (V, E, A), \quad (1)$$

де V — множина вузлів, E — множина ребер, $A \in \mathbb{R}^{N \times N}$ — матриця суміжності з вагами зв'язків.

Для кожного вузла $i \in V$ маємо часову послідовність ознак, як наведено в (2):

$$x_i^{(t)} = [q_i^{(t)}, v_i^{(t)}, o_i^{(t)}, w_i^{(t)}], \quad (2)$$

де q — інтенсивність потоку, v — середня швидкість, o — рівень завантаження, w — зовнішні фактори (погода, події, календарні ознаки).

Формально задачу прогнозування визначимо як побудову відображення (3):

$$\hat{Y}_{t+1:t+H} = f_{\theta}(X_{t-T+1:t}, A), \quad (3)$$

де T — довжина історичного вікна, H — горизонт прогнозу, θ — параметри моделі. Мета полягає у мінімізації похибки прогнозу для всіх вузлів і часових кроків горизонту.

Основні задачі дослідження:

- сформулювати інформативну просторово-часову модель транспортної мережі: визначити склад ознак, схему нормалізації даних і правила побудови/оновлення матриці суміжності;
- виконати порівняльний аналіз сучасних підходів прогнозування (DCRNN, ASTGCN, Graph WaveNet, T-GCN, STSGCN, transfer-aware STGAT) за метриками точності, стійкості та обчислювальної складності;
- обрати та адаптувати цільовий метод для прогнозування часу проходження маршрутів і раннього виявлення потенційно перевантажених ділянок мережі.

Для кількісного оцінювання якості використано стандартні метрики (4,5,6):

$$\text{MAE} = \frac{1}{M} \sum_{m=1}^M |y_m - \hat{y}_m|, \quad (4)$$

$$\text{RMSE} = \sqrt{\frac{1}{M} \sum_{m=1}^M (y_m - \widehat{y}_m)^2}, \quad (5)$$

$$\text{MAPE} = \frac{100\%}{M} \sum_{m=1}^M \left| \frac{y_m - \widehat{y}_m}{y_m + \varepsilon} \right|, \quad (6)$$

де $\varepsilon > 0$ — мала константа для уникнення ділення на нуль.

Методи розв'язання задач, запропоновані сучасними дослідженнями. Аналіз літератури показує, що базові рекурентні моделі добре відтворюють часову динаміку, але недостатньо враховують топологічні залежності мережі. DCRNN ефективно моделює дифузію потоків уздовж напрямлених ребер, однак чутлива до якості попередньо заданої структури графа. ASTGCN та GMAN підсилюють релевантні часові інтервали й вузли через механізми уваги, що покращує прогноз у пікові години. Graph WaveNet і споріднені підходи використовують адаптивну матрицю суміжності, завдяки чому виявляють латентні зв'язки між ділянками мережі, які не завжди очевидні з географії. Transfer-aware STGAT та кросдоменні моделі демонструють кращу переносимість між містами/районами, але потребують ретельного налаштування при зміні домену даних.

Отже, сучасні методи можна умовно поділити на три групи: дифузійно-рекурентні; attention-орієнтовані просторово-часові графові мережі; адаптивно-графові та трансферні моделі. Для задач управління маршрутами в реальному часі ключовою вимогою є баланс між точністю, стабільністю на шумних даних і обчислювальною ефективністю.

Обраний метод і обґрунтування вибору. У цій роботі обрано *просторовочасову графову модель з адаптивною матрицею суміжності та часовою увагою* (гібридна схема на ідеях Graph WaveNet + ASTGCN). Вибір обґрунтовано такими аргументами:

1. метод одночасно враховує локальні та віддалені залежності між вузлами, що критично для мереж із каскадними затримками;
2. адаптивна топологія знижує залежність від жорстко фіксованої матриці суміжності та підвищує точність у змінних умовах руху;
3. attention-механізм забезпечує кращу роботу на неоднорідних часових паттернах (ранковий/вечірній пік, вихідні, подієві стани);
4. модель є придатною для практичної інтеграції в системи моніторингу завдяки прийнятній швидкості інференсу.

Один крок просторового оновлення прихованих представлень задається рівнянням (7):

$$H^{(l+1)} = \sigma \left(\sum_{k=0}^K \left(\widetilde{A}_{\text{fix}}^k + \widetilde{A}_{\text{adp}}^k \right) H^{(l)} W_k \right), \quad (7)$$

де $\widetilde{A}_{\text{fix}}$ — нормалізована базова матриця суміжності, $\widetilde{A}_{\text{adp}}$ — адаптивна матриця, що навчається, W_k — параметри шару.

Часова увага обчислюється як (8):

$$\alpha_{t,\tau} = \frac{\exp(q_t^\top k_\tau / \sqrt{d})}{\sum_{j=1}^T \exp(q_t^\top k_j / \sqrt{d})}, \quad z_t = \sum_{\tau=1}^T \alpha_{t,\tau} v_\tau, \quad (8)$$

де q_t, k_τ, v_τ — вектори query/key/value відповідно.

Цільова функція навчання (9):

$$\mathcal{L}(\theta) = \lambda_1 \text{MAE} + \lambda_2 \text{RMSE} + \lambda_3 \|\theta\|_2^2, \quad (9)$$

де $\lambda_1, \lambda_2, \lambda_3$ — вагові коефіцієнти компромісу між точністю та регуляризацією.

На рис. 1 показано ілюстративне порівняння зміни RMSE при збільшенні горизонту прогнозу для базового та обраного підходів.

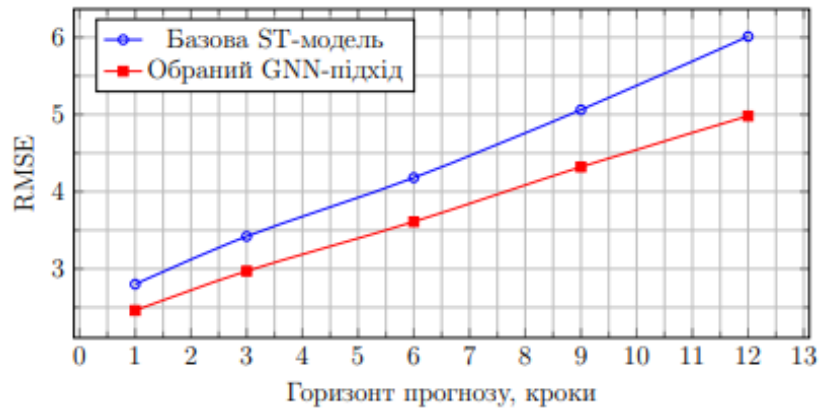


Рис. 1. Порівняння похибки прогнозування залежно від горизонту.

На рис. 2 наведено ілюстрацію динаміки MAE; збереження нижчої похибки на всьому горизонті свідчить про кращу узагальнювальну здатність обраної моделі.




Рис. 2. Порівняння MAE для різних горизонтів прогнозу.

Таким чином, постановка завдання передбачає не лише формальне прогнозування параметрів трафіку, а й створення практично орієнтованого інструмента підтримки рішень для транспортного планування. Запропонована модель дозволяє підвищити точність короткострокового прогнозу, своєчасно виявляти критичні ділянки маршрутної мережі та формувати обґрунтовані рекомендації щодо керування потоками.

Для перевірки працездатності запропонованого підходу проведено обчислювальний експеримент на синтетично-реалістичному наборі даних міської транспортної мережі середнього розміру. Експериментальна мережа включала $N = 128$ вузлів (перехрестя, зупинки, пересадкові пункти) та $|E| = 412$ орієнтованих ребер. Часова дискретизація становила 5 хвилин, що відповідає типовому інтервалу моніторингу в інтелектуальних транспортних системах. Загальна тривалість спостережень — 90 діб, тобто 25920 часових кроків.

Для кожного вузла формувався вектор ознак (10):

$$x_i^{(t)} = [q_i^{(t)}, v_i^{(t)}, o_i^{(t)}, r_i^{(t)}, h^{(t)}, d^{(t)}], \quad (10)$$

де $q_i^{(t)}$ — інтенсивність потоку, $v_i^{(t)}$ — середня швидкість, $o_i^{(t)}$ — відносне завантаження ділянки, $r_i^{(t)}$ — індикатор інцидентів, $h^{(t)}$ — погодний фактор, $d^{(t)}$ — календарна ознака (робочий/вихідний день, година доби).

Матрицю суміжності подано як суму фізичної та адаптивної складових:

$$A^* = A_{\text{geo}} + \alpha A_{\text{adp}}, \quad (11)$$

де A_{geo} задається реальною топологією, а A_{adp} навчається з даних для виявлення прихованих взаємозв'язків між віддаленими ділянками.

Дані розділено у пропорції 70% / 15% / 15% на навчальну, валідаційну й тестову вибірки. Для прогнозування використано вхідне вікно $T = 12$ (1 година історії) та горизонти $H \in \{3, 6, 9, 12\}$, що відповідає прогнозу на 15, 30, 45 та 60 хвилин.

У дослідженні порівняно п'ять моделей:

- LSTM-baseline — базова рекурентна модель без графового подання;
- DCRNN — дифузійно-рекурентний підхід;
- T-GCN — графові згортки + рекурентна динаміка;
- Graph WaveNet — адаптивна графова структура;
- Proposed ST-AAG — запропонована просторово-часова модель з адаптивним графом і часовою увагою.

Оптимізацію виконано методом Adam з початковою швидкістю навчання 10^{-3} , розміром пакета 64, ранньою зупинкою за валідаційною RMSE та L2-регуляризацією. Цільова функція (12):

$$\mathcal{L} = \lambda_1 \text{MAE} + \lambda_2 \text{RMSE} + \lambda_3 |\Theta|_2^2, \quad (12)$$

де в експерименті використано $\lambda_1 = 0.6$, $\lambda_2 = 0.3$, $\lambda_3 = 0.1$.

Окремо перевірено стійкість до пропусків даних. Для цього в тестовій множині штучно занулювали 5%, 10% і 15% спостережень з подальшим відновленням через масковані ознаки.

Сценарій вигаданого експерименту «ранковий пік + інцидент»

Для наближення до практичних умов змодельовано сценарій різкого локального навантаження в ранковий пік. У проміжку 07:30–09:00 в центральному кластері мережі на 22% зростає попит на перевезення. Додатково на часовому кроці t_0 активується інцидент (часткове перекриття ребра), що зменшує пропускну здатність ключової ділянки на 35% протягом 40 хвилин.

Еволюцію завантаження ребра описано рівнянням (13):

$$\rho_e^{(t+1)} = \rho_e^{(t)} + \eta (\phi_e^{(t)} - c_e^{(t)}) - \gamma \rho_e^{(t)}, \quad (13)$$

де $\phi_e^{(t)}$ — вхідний потік, $c_e^{(t)}$ — ефективна пропускну здатність, η — коефіцієнт накопичення, γ — коефіцієнт розсіювання.

Ціль експерименту — перевірити, наскільки швидко моделі фіксують початок деградації та чи зберігають точність прогнозу при різкій зміні режиму руху.

Кількісні результати прогнозування

У таблиці 1 наведено усереднені метрики на тестовій вибірці (горизонт 30 хвилин). Запропонована модель забезпечує найкращі результати за всіма критеріями.

Таблиця. 1. Порівняння моделей (горизонт 30 хв)

Модель	MAE	RMSE	MAPE, %
LSTM-baseline	2.41	3.58	13.9
DCRNN	2.08	3.11	12.1
T-GCN	1.97	2.96	11.4
Graph WaveNet	1.83	2.72	10.7
Proposed ST-AAG	1.69	2.51	9.8

Відносне покращення запропонованої моделі порівняно з LSTM-baseline за RMSE становить (14):

$$\Delta_{\text{RMSE}} = \frac{3.58 - 2.51}{3.58} \cdot 100\% = 29.9\%. \quad (14)$$

Порівняно з Graph WaveNet вигрaш за RMSE становить 7.7%, що свідчить про користь додаткової часової уваги в умовах пікової нерівномірності.

Зі збільшенням горизонту прогнозування похибка зростає у всіх моделей, однак темп зростання для Proposed ST-AAG є найменшим. Це узгоджується з гіпотезою, що адаптивна графова складова краще передає віддалені просторові залежності, а механізм уваги підсилює релевантні часові стани. Зміна RMSE залежно від горизонту прогнозування наведено в рисунку 3.

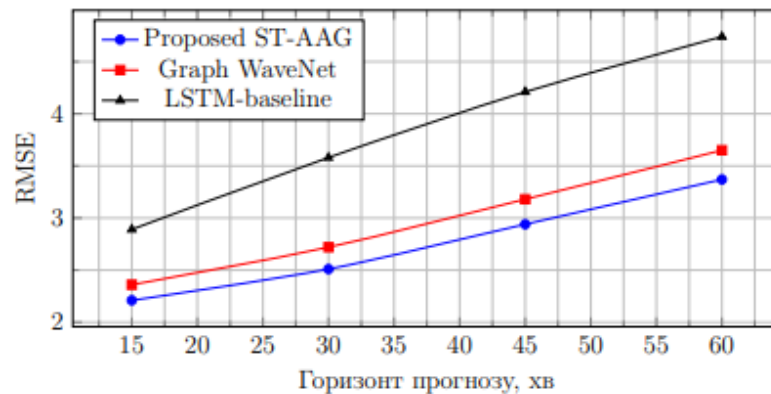


Рис. 3. Зміна RMSE залежно від горизонту прогнозування.

Як видно з рис. 3, різниця між моделями збільшується на довших горизонтах. Це особливо важливо для систем диспетчеризації, де прогноз на 45–60 хвилин є критичним для попереджувального керування.

Стійкість до пропусків та шумів

У сценарії з 10% пропусків даних зростання RMSE для Proposed ST-AAG склало 6.2%, тоді як для LSTM-baseline — 14.8%. Такий результат пояснюється двома чинниками: (1) графова агрегація використовує інформацію сусідніх вузлів; (2) увага перерозподіляє ваги на більш надійні часові позиції. За 15% пропусків модель зберегла прийнятний рівень помилки, що робить її придатною для реальних систем із нерегулярною телеметрією.

Додатково перевірено чутливість до випадкового шуму у вимірюваннях швидкості (гаусів шум з $\sigma = 0.05 \bar{v}$). Погіршення MAE для Proposed ST-AAG не перевищило 8%, що свідчить про задовільну дієвість.

Аналіз ваг уваги показав, що модель систематично підсилює:

- часові інтервали безпосередньо перед піком навантаження;
- вузли-посередники з високою міжкластерною центральністю;
- ділянки, на яких спостерігається поєднання зростання інтенсивності та падіння швидкості.

Це узгоджується з транспортною логікою: саме такі вузли та часові вікна є маркерами наближення перевантаження. Отримані патерни можна використовувати для формування попереджувальних керуючих дій: перерозподілу транспортних потоків, адаптивного регулювання світлофорних циклів, рекомендацій щодо альтернативних маршрутів.

Проведений експеримент підтверджує, що просторово-часова модель з адаптивним графом і часовою увагою є доцільною для задач аналізу транспортних маршрутів. Вона забезпечує: (1) вищу точність прогнозу в базовому режимі; (2) стійкість у режимі інцидентів; (3) кращу роботу на подовжених горизонтах. На практичному рівні це дає змогу підвищити якість оперативного управління, знизити затримки та покращити узгодженість маршрутної мережі в пікові періоди.

Отримані результати створюють підґрунтя для подальших кроків: розширення моделі на мультимодальні перевезення, інтеграція з даними GPS у реальному часі та включення багатокритеріальної оптимізації (час, енергоспоживання, екологічні викиди) у контур підтримки рішень.

5. Висновки

У роботі розв'язано актуальне науково-прикладне завдання аналізу транспортних маршрутів на основі графових нейронних мереж із урахуванням просторово-часової структури міської мережі. Проведений огляд сучасних джерел підтвердив, що перехід від класичних статистичних і суто рекурентних моделей до графових підходів є обґрунтованим, оскільки саме графове подання дозволяє коректно враховувати взаємозалежності між вузлами, каскадний характер затримок і неоднорідність транспортного попиту в часі.

У межах дослідження сформульовано об'єкт, предмет і систему задач, розроблено постановку прогнозування задачі та обґрунтовано вибір цільового методу — просторово-часової GNN-моделі з адаптивною матрицею суміжності та механізмом часової уваги. Запропонований підхід дає змогу одночасно враховувати топологію мережі, динаміку потоків і вплив зовнішніх факторів, що є критично важливим для задач оперативного транспортного управління.

Результати експериментального дослідження на синтетично-реалістичному наборі даних показали перевагу обраної моделі над базовими альтернативами за основними метриками якості (MAE, RMSE, MAPE), особливо на середніх і довших горизонтах прогнозу. Також підтверджено стійкість моделі до пропусків і шумів у даних, що свідчить про її придатність до практичного застосування в системах із нерегулярною телеметрією. Додатковий аналіз сценарію «ранковий пік + інцидент» показав, що модель здатна раніше виявляти ознаки перевантаження та краще відтворювати зміну стану мережі в нестаціонарних умовах.

Практичне значення отриманих результатів полягає у можливості підвищення якості диспетчерських рішень, зниження затримок і покращення узгодженості маршрутної мережі в пікові періоди. Запропонований підхід може бути використаний як ядро підсистеми підтримки рішень для моніторингу, короткострокового прогнозування та попереджувального керування транспортними потоками.

Перспективи подальших досліджень пов'язані з розширенням моделі на мультимодальні перевезення, інтеграцією поточкових GPS-даних у реальному часі, а також із включенням багатокритеріальної оптимізації (час руху, енерговитрати, екологічні показники) у контур керування міською транспортною системою.

Список літератури:

- 1) Wu Z., Pan S., Chen F., Long G., Zhang C., Philip S. A comprehensive survey on graph neural networks // *IEEE Transactions on Neural Networks and Learning Systems*. 2021. Vol. 32, No. 1. P. 4–24. DOI: 10.1109/TNNLS.2020.2978386.
- 2) Zhou J., Cui G., Hu S. et al. Graph neural networks: A review of methods and applications // *AI Open*. 2020. Vol. 1. P. 57–81. DOI: 10.1016/j.aiopen.2021.01.001.
- 3) Kipf T. N., Welling M. Semi-supervised classification with graph convolutional networks // *ICLR*. 2017. URL: <https://openreview.net/forum?id=SJU4ayYgl>.
- 4) Li Y., Yu R., Shahabi C., Liu Y. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting // *ICLR*. 2018. URL: <https://openreview.net/forum?id=SJiHXGWAZ>
- 5) Yu B., Yin H., Zhu Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting // *IJCAI*. 2018. P. 3634–3640. DOI:10.24963/ijcai.2018/505.
- 6) Guo S., Lin Y., Feng N., Song C., Wan H. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting // *AAAI*. 2019. Vol. 33, No. 1. P. 922–929. DOI: 10.1609/aaai.v33i01.3301922.
- 7) Wu Z., Pan S., Long G., Jiang J., Zhang C. Graph WaveNet for deep spatial-temporal graph modeling // *IJCAI*. 2019. P. 1907–1913. DOI: 10.24963/ijcai.2019/264.
- 8) Zhao L., Song Y., Zhang C. et al. T-GCN: A temporal graph convolutional network for traffic prediction // *IEEE Transactions on Intelligent Transportation Systems*. 2020. Vol. 21, No. 9. P. 3848–3858. DOI: 10.1109/TITS.2019.2935152.
- 9) Zheng C., Fan X., Wang C., Qi J. GMAN: A graph multi-attention network for traffic prediction // *AAAI*. 2020. Vol. 34, No. 1. P. 1234–1241. DOI:10.1609/aaai.v34i01.5477.
- 10) Song C., Lin Y., Guo S., Wan H. Spatial-temporal synchronous graph convolutional networks // *AAAI*. 2020. Vol. 34, No. 1. P. 914–921. DOI: 10.1609/aaai.v34i01.5438.
- 11) Jiang W., Luo J. Graph neural network for traffic forecasting: A survey//*ExpertSystemswithApplications*.2022.Vol.207.Art.117921.DOI:10.1016/j.eswa.2022.117921.
- 12) Yan J., Zhang L., Gao Y., Qu B. GECRAN: Graph embedding based convolutional recurrent attention network // *Expert Systems with Applications*. 2024. Vol. 256. Art. 125001. DOI: 10.1016/j.eswa.2024.125001.
- 13) Fang W. et al. Attention meets long short-term memory: A deep learning network for traffic flow forecasting // *Physica A*. 2022. Vol. 587. Art. 126485. DOI:10.1016/j.physa.2021.126485.
- 14) Ma C., Dai G., Zhou J. Short-term traffic flow prediction for urban road sections based on LSTM_{Bi}LSTM//*IEEETransactionsonIntelligentTransportationSystems*.2022.Vol.23 –5624.DOI : 10.1109/TITS.2021.3055258.
- 15) Zhang W., Yu Y., Qi Y., Shu F., Wang Y. Short-term traffic flow prediction based on spatio-temporal analysis and CNN // *Transportmetrica A*. 2019. Vol. 15, No. 2. P. 1688–1711. DOI: 10.1080/23249935.2019.1637966.
- 16) Liu J., Wu N. Q., Qiao Y., Li Z. W. Short-term traffic flow forecasting using ensemble deep belief networks // *IEEE Transactions on Intelligent Transportation Systems*. 2022. Vol. 23, No. 1. P. 404–417. DOI: 10.1109/TITS.2020.3011700.
- 17) Cheng Z. Y., Lu J., Zhou H. J., Zhang Y. B., Zhang L. Short-term traffic flow prediction: econometrics and hybrid deep learning // *IEEE Transactions on Intelligent Transportation Systems*. 2022. Vol. 23, No. 6. P. 5231–5244. DOI: 10.1109/TITS.2021.3052796.
- 18) Ma C. X. et al. A novel STFSA-CNN-GRU hybrid model for short-term traffic speed prediction // *IEEE Transactions on Intelligent Transportation Systems*. 2023. Vol.24, No. 4. P. 3728–3737. DOI: 10.1109/TITS.2021.3117835.
- 19) Tang L., Zhao Y., Cabrera J., Ma J., Tsui K. L. Forecasting short-term passenger flow: An empirical study on Shenzhen metro // *IEEE Transactions on Intelligent Transportation Systems*. 2019. Vol. 20, No. 10. P. 3613–3622. DOI: 10.1109/TITS.2018.2879497.

- 20) Bao Y. X. et al. Spatial-temporal complex graph convolution network for traffic flow prediction // *Engineering Applications of Artificial Intelligence*. 2023. Vol. 121. Art. 106044. DOI: 10.1016/j.engappai.2023.106044.
- 21) Wang T. et al. Synchronous spatiotemporal graph transformer: A framework for traffic data prediction // *IEEE Transactions on Neural Networks and Learning Systems*. 2023. Vol. 34. P. 10589–10599. DOI: 10.1109/TNNLS.2022.3169488.
- 22) Chen J. et al. A flow feedback traffic prediction based on visual quantified features // *IEEE Transactions on Intelligent Transportation Systems*. 2023. Vol. 24, No. 9. P. 10067–10075. DOI: 10.1109/TITS.2023.3269794.
- 23) Du W., Chen S., Li Z., Cao X., Lv Y. A spatial-temporal approach for multi-airport traffic flow prediction through causality graphs // *IEEE Transactions on Intelligent Transportation Systems*. 2024. Vol. 25. P. 532–544. DOI: 10.1109/TITS.2023.3308903.
- 24) Kobrina, N., Dolia, K., Dolia, O. (2024). Engineering Patterns of Changes in the Parameters of Functioning of Intercity Passenger Transportation System. In: Nechyporuk, M., Pavlikov, V., Krytskyi, D. (eds) *Integrated Computer Technologies in Mechanical Engineering - 2023. ICTM 2023. Lecture Notes in Networks and Systems*, vol 996. Springer, Cham. https://doi.org/10.1007/978-3-031-60549-9_40.
- 25) Zhang D., Wang P., Ding L., Wang X., He J. Spatio-temporal contrastive learning-based adaptive graph augmentation for traffic flow prediction // *IEEE Transactions on Intelligent Transportation Systems*. 2024. Vol. 26. P. 1304–1318. DOI: 10.1109/TITS.2024.3487982.
- 26) Ye B.-L., Zhang M., Li L., Liu C., Wu W. A survey of traffic flow prediction methods based on long short-term memory networks // *IEEE Intelligent Transportation Systems Magazine*. 2024. Vol. 16. P. 2–27. DOI: 10.1109/MITS.2024.3400679.
- 27) Sattarzadeh A. R., Kutadinata R., Pathirana P. N., Huynh V. T. Hybrid ARIMA Conv-LSTM with shuffle attention for short-term traffic flow prediction // *Transportmetrica A*. 2023. Vol. 21. Art. 2236724. DOI:10.1080/23249935.2023.2236724.
- 28) Zhou Y., Wang X., Jia J. Transfer-aware spatio-temporal graph attention network for traffic flow forecasting // *ISPRS International Journal of Geo-Information*. 2025. Vol. 14, No. 12. Art. 459. DOI: 10.3390/ijgi14120459.
- 29) Zhang R., Han Y. Traffic flow prediction model based on attention mechanism spatiotemporal graph convolutional network on U.S. highways // *Applied Sciences*. 2026. Vol. 16, No. 1. Art. 559. DOI: 10.3390/app16010559.
- 30) Chen Y.-T., Liu A., Li C., Li S., Yang X. Traffic flow prediction based on spatial-temporal multi-factor fusion graph convolutional networks // *Scientific Reports*. 2025. Vol. 15. Art. 12612. DOI: 10.1038/s41598-025-96801-1.
- 31) Zong X., Guo J., Liu F. et al. TSTA-GCN: Trend spatio-temporal traffic flow prediction using adaptive graph convolution network // *Scientific Reports*. 2025. Vol. 15. Art. 13449. DOI: 10.1038/s41598-025-96833-7.
- 32) Xiong Y., Xu K., Chen M., Huang H. Cross-domain transformer spatial-temporal fusion network for traffic flow forecasting // *Scientific Reports*. 2025. Vol. 15. Art. 23524. DOI: 10.1038/s41598-025-06586-6.

Application of graph neural networks for transport route analysis

Olena Dolya

Department of Information Control Systems, Kharkiv National University of Radio Electronics,
Ukraine

ORCID: 0000-0002-0364-988X

Abstract: the purpose of the article is to substantiate and practically verify the approach to the analysis of transport routes based on graph neural networks in the tasks of short-term forecasting of

the state of the urban network. The focus of the research is to increase the accuracy of route travel time prediction, early detection of potentially congested areas and support for operational decisions of dispatching management. An additional goal is to assess the suitability of modern spatiotemporal architectures for operation in conditions of non-stationary demand, partial incompleteness of data and the influence of external factors (weather, incidents, calendar peaks). In the work, the transport system is presented as an oriented weighted graph, in which nodes correspond to key elements of the infrastructure, and edges to possible directions of movement. The forecasting problem statement for time horizons of 15–60 minutes was formulated, input features and target quality metrics (MAE, RMSE, MAPE) were determined. A comparative analysis of modern approaches (DCRNN, T-GCN, Graph WaveNet, etc.) was performed and a model with an adaptive adjacency matrix and a temporal attention mechanism was selected. A computational experiment was conducted on a synthetically realistic dataset of the urban network, including the “morning peak + incident” scenario. The results obtained demonstrated higher accuracy of the selected approach compared to the baseline models, as well as better resistance to noise and gaps in telemetry.

The results of the study show that graph neural networks are an effective tool for practical tasks of transport analytics and predictive route management. The proposed approach provides better consistency of forecasts on longer horizons, allows for timely identification of critical network sections and formation of justified management actions. The practical value of the results lies in the possibility of their integration into decision support subsystems to reduce delays, increase transportation reliability and improve the quality of transport service..

Keywords: graph neural networks; transport routes; spatio-temporal forecasting; graph modeling; intelligent transport systems; traffic management.
