

DOI: <https://doi.org/10.36910/6775-2524-0560-2026-63-21>

УДК 656.13:004.852:004.94

Лім Стас Дмитрович¹, магістр

<https://orcid.org/0009-0000-5808-7258>

Лавров Євгеній Анатолійович^{1,2}, д.т.н., професор,

<https://orcid.org/0000-0001-9117-5727>

Чибіряк Яна Іванівна², к.т.н., доцент,

<https://orcid.org/0000-0002-0634-7609>

¹Міжнародний університет інформаційних технологій, м. Алмати, Казахстан

²Сумський державний університет, м. Суми, Україна

ПРОГНОСТИЧНА МАРШРУТИЗАЦІЯ ТРАНСПОРТНИХ ЗАСОБІВ НА ОСНОВІ ПРОСТОРОВО-ЧАСОВОЇ ГРАФОВОЇ МЕРЕЖІ З МЕХАНІЗМОМ УВАГИ

Лім С. Д., Лавров Є. А., Чибіряк Я.І. Прогностична маршрутизація транспортних засобів на основі просторово-часової графової мережі з механізмом уваги. Реактивна маршрутизація транспорту реагує на дорожні затори вже після їх появи та відстає від динаміки утворення вузьких місць за умов високого попиту, що знижує її ефективність, коли міські мережі функціонують на межі пропускної здатності. У дослідженні запропоновано систему прогностичної маршрутизації STGAT-PR, яка інтегрує короткострокові прогнози часу проїзду ребер транспортного графа як вагові коефіцієнти в алгоритм пошуку найкоротшого шляху у глобальному циклі перемаршрутизації Дейкстри. Прогностична архітектура моделі поєднує механізм графової уваги (GAT) на двоїстому графі дорожньої мережі з вентиляним рекурентним блоком (GRU), що забезпечує виділення просторово-часових ознак із поточного стану мережі. Систему реалізовано у вигляді замкненого циклу керування на базі мікроскопічного симулятора SUMO та валідовано на деталізованому сценарії транспортної мережі Монако. Проведено порівняльний аналіз п'яти стратегій маршрутизації за двох рівнів попиту з використанням незалежних наборів псевдовипадкових чисел. Статистичну значущість результатів підтверджено парними критеріями та оцінкою розміру ефекту. Встановлено, що прогностична маршрутизація знижує середній час поїздки та підвищує стабільність маршрутів порівняно з реактивними базовими підходами, причому ця перевага максимізується за умов підвищеного попиту. Доведено, що механізм просторової уваги робить визначальний внесок у підвищення продуктивності моделі. Запропоновану імітаційну модель можна повторно використовувати для кількісного порівняння стратегій маршрутизації перед їх запровадженням у системах керування трафіком розумного міста.

Ключові слова: прогностична маршрутизація, графові мережі уваги (GAT), імітаційна модель, прогнозування часу проїзду, мікроскопічне моделювання трафіку, симулятор SUMO, сценарій MoST, алгоритм Дейкстри, перемаршрутизація, структура системи, пропускна здатність, робоча завантаженість.

Lim S., Lavrov Ye., Chybiriak Ya. Predictive Vehicle Routing Based on a Spatial-Temporal Graph Attention Network. Reactive vehicle routing acts on congestion after it has formed and lags the growth of bottlenecks under heavy demand, which limits its effectiveness as urban networks operate closer to capacity. This paper presents STGAT-PR, a predictive-routing system that integrates a short-term forecast of edge travel times directly into the edge weights of a global Dijkstra rerouting loop. The forecasting model combines a graph attention layer over the dual graph of road edges with a gated recurrent unit, learning content-dependent spatial dependencies and temporal dynamics from the recent network state. The system is implemented as a closed loop around the SUMO microscopic simulator and evaluated on the realistic urban scenario of Monaco. Five routing strategies are compared at two demand levels with independent random seeds, and statistical significance is assessed with paired hypothesis tests and effect sizes. Predictive routing reduces mean travel time and improves the reliability of routes compared to reactive baselines, with a stronger advantage under elevated demand; the spatial attention component provides a measurable share of the gain. The simulation model can be reused for quantitative comparison of routing strategies before deployment in smart-city traffic-management systems.

Keywords: predictive routing, Graph Attention Networks (GAT), simulation model, travel time prediction, microscopic traffic simulation, SUMO simulator, MoST scenario, Dijkstra's algorithm, rerouting, system architecture, network capacity, operational load.

Постановка наукової проблеми. У 2024 році індивідуальні втрати часу водіїв Лондона в заторах становили 101 годину, а сукупні збитки для економіки Великої Британії сягнули 7.7 млрд. фунтів стерлінгів [1]. У Дюссельдорфі річне зростання тривалості затримок склало 22 %. Попри очікування, що пандемія COVID трансформує моделі міської мобільності, актуальні дані свідчать про зворотну тенденцію: рівень заторів у європейських містах повернувся до показників 2020 року, незважаючи на поширення дистанційної та гібридної зайнятості [2]. Місця локалізації цих затримок не є випадковими. Сучасні дослідження дорожніх мереж виявляють обмежену множину стійких «вузьких місць» як основне джерело уповільнення трафіку в масштабах міста [3]. Згідно з TomTom Traffic Index 2024, Дублін та Лодзь увійшли до п'ятірки найбільш завантажених міст світу поряд із Мехіко, Бенгалуру та Пуне [4].

Регуляторна відповідь Європейського Союзу була закріплена законодавчо: Директива 2010/40/ЄС зобов'язує держави-члени впроваджувати спільну архітектуру інтелектуальних

транспортних систем (ІТС). Зокрема, стаття 2 Директиви визначає оптимізацію використання дорожніх і транспортних даних як пріоритетний напрям розвитку [5]. Таке структурування пріоритетів свідчить про перехід управління трафіком на основі даних із науково-дослідної площини в категорію обов'язкових до реалізації практичних заходів.

Практична реалізація цих стратегій має системний характер. Зокрема, у Польщі спостерігається інтенсивне розгортання інтелектуальних систем: у Варшаві, Кракові, Вроцлаві, Гданську, Познані, Катовіце та Лодзі застосовують різні комбінації динамічного керування світлофорами, інтелектуальних пішохідних переходів і модулів прогнозування ДТП. Нещодавні дослідження цих муніципальних систем базуються на поєднанні краудсорсингових даних про мобільність із моделями машинного навчання для аналізу патернів трафіку [6]. В інших європейських містах розвиток аналогічних систем має специфічну спрямованість: Берлін застосовує штучний інтелект для регулювання сигналів і паркування, Мадрид пілотує парк автономних автобусів, а Амстердам інтегрував велоінфраструктуру безпосередньо в рівень ІТС [7].

Спільним обмеженням наявних рішень є часовий лаг: системи реагують на затори лише за фактом їхнього виникнення. Наявні прогностичні компоненти зазвичай функціонують на рівні загальномережевого моніторингу, а не маршрутизації окремих транспортних засобів.

Це зумовлює наукову прогалину. Реактивна перемаршрутизація, навіть за умови використання даних у режимі реального часу, виявляється інерційною в умовах високого навантаження: на момент спрацювання алгоритму критична ділянка вже завантажена. Прогностичний маршрутизатор, ваги ребер якого базуються на прогнозі стану мережі, потенційно дозволяє уникати заторів до їхнього формування. Ефективність такої стратегії залежить від якості прогностичної моделі, що має враховувати просторову топологію мережі та часову динаміку потоку.

Метою даного дослідження є комп'ютерне моделювання прогностичної маршрутизації транспортних засобів на основі просторово-часової графової мережі з механізмом уваги (STGAT) з кількісною оцінкою її ефективності порівняно з реактивними стратегіями за різних рівнів попиту.

Аналіз останніх досліджень і публікацій. Перемаршрутизація транспорту в дорожніх мережах поділяється на дві парадигми: реактивну, що базується на поточних вимірюваннях стану мережі, та прогностичну, що орієнтована на майбутній стан. Різниця цих підходів зумовлена специфікою формування вагових коефіцієнтів ребер графа у задачах пошуку найкоротшого шляху, тоді як базовий алгоритм пошуку може залишатися незмінним.

Реактивний підхід ґрунтується на класичних методах маршрутизації. Алгоритм Дейкстри [8] є основним інструментом динамічного керування: адаптація статичних ваг вільного потоку до актуальних показників часу проїзду дозволяє системі реагувати на миттєві зміни стану мережі. Використання алгоритму A^* [9] забезпечує вищу швидкість обчислень на евклідових мережах завдяки впровадженню евристичних функцій. Проте в умовах щільної міської забудови з обмеженнями одностороннього руху та частими зупинками ефективність евристики знижується. Враховуючи низьку обчислювальну вартість одиничного запиту в межах мікроскопічного моделювання, перевага алгоритму A^* у швидкості стає несуттєвою. Релевантним прикладом сучасної реактивної схеми є стратегія динамічної адаптивної перемаршрутизації Wang [10], яка інтегрує пошук k -найкоротших шляхів із періодичним оновленням даних на основі поточних вимірювань без залучення V2I-інфраструктури. Автори зазначають, що превентивне уникнення заторів на основі короткострокового прогнозування є відкритим науковим питанням, розв'язанню якого присвячено дане дослідження.

Прогностичний підхід передбачає заміну ваг ребер, що відповідають поточному стану мережі, вихідними даними моделі прогнозування трафіку. У фаховій літературі для одночасного врахування графової структури дорожньої мережі та часової динаміки потоку домінують два архітектурні компоненти: графові мережі з механізмом уваги (GAT) [11], що забезпечують зважене агрегування ознак сусідніх вузлів для фіксації просторових залежностей, та вентильні рекурентні блоки (GRU) [12], які моделюють часову динаміку з меншою кількістю параметрів порівняно з LSTM. Канонічним прикладом такого поєднання є модель T-GCN [13], де шар графової згортки інтегровано з GRU для наскрізного прогнозування на основі ковзного вікна історії. Однак у T-GCN агрегування обмежене топологією: вага кожного сусіда визначається нормалізованою матрицею суміжності незалежно від його поточного стану. Застосування механізму уваги (GAT) нівелює це обмеження, дозволяючи моделі обчислювати попарні ваги на основі ознак вузлів на кожному часовому кроці. Це дозволяє динамічно підсилювати вплив завантажених ділянок порівняно з

вільними другорядними вулицями. Моделі STCGAT [14] та DSTGAT [15] розвивають цей підхід, використовуючи вузло-адаптивні механізми та багаторівневі просторово-часові блоки.

Модель STGAT-PR, запропонована у цій роботі, базується на конфігурації GAT-GRU з чотирма головами уваги, прихованою розмірністю 32 (GAT) та 64 (GRU), десятикроковим вікном історії та п'ятикроковим горизонтом прогнозування. Наукова новизна полягає не в розробці архітектури, а в реалізації замкненого циклу інтеграції прогнозів GAT+GRU в алгоритм перемаршрутизації Дейкстри для кожного транспортного засобу. Ефективність системи валідована на реалістичному мікроскопічному сценарії з використанням 20 незалежних випадкових реалізацій та статистичним тестуванням парних гіпотез.

Реалізація замкненого циклу «прогноз - маршрутне рішення» потребує моделювання на рівні окремих транспортних засобів. Варто зазначити, що імітаційне моделювання загалом є універсальним інструментом [16-18], який успішно застосовується для аналізу та пошуку резервів підвищення ефективності різноманітних складних систем, включаючи автоматизовані системи та виробничі процеси [19-21], медичні системи [22], а також комунікаційні та локальні обчислювальні мережі [23, 24]. У контексті безпосередньо транспортних задач, підходи до імітації трафіку поділяються на макроскопічні та мікроскопічні [25]. Макроскопічні моделі оперують агрегованими показниками щільності та швидкості потоку, що не дозволяє аналізувати індивідуальні рішення щодо зміни маршруту. Натомість мікроскопічні моделі відтворюють рух кожного об'єкта згідно з алгоритмами прямування за лідером (*car-following*) та зміни смуги (*lane-changing*). Такий рівень деталізації є критичним для оцінки впливу різних схем зважування ребер на час прибуття конкретного транспортного засобу. Відповідно, у цьому дослідженні застосовано мікроскопічний підхід.

Більшість досліджень у сфері мікроскопічного моделювання дорожнього руху базуються на використанні трьох інструментів: комерційного пакета VISSIM (розробка PTV) та двох рішень із відкритим кодом – MATSim (ETH Zurich) і SUMO (DLR). Результати порівняльних оцінок цих платформ є неоднозначними. В роботі Anyin [26] VISSIM визначено як найбільш ефективний за комплексним індексом масштабованості, проте зазначено, що SUMO та MATSim не поступаються йому за показниками часу обчислень та використання пам'яті. Diallo та співавт. [27], враховуючи критерії інтермодальної мобільності, надають перевагу MATSim. З огляду на відсутність консенсусу в літературі, вибір симулятора зумовлюється специфічними вимогами дослідження (табл. 1).

Таблиця 1. Порівняльний аналіз мікроскопічних симуляторів

Критерій	SUMO	VISSIM	MATSim
Ліцензія	Відкрита (EPL 2.0)	Комерційна	Відкрита (GPL)
Python API для інтеграції з ML	Нативний (TraCI)	Опосередкований (COM)	Опосередкований (Py4J)
Модель прямування за лідером	Підтримка IDM (вбудовано)	Wiedemann; IDM (опційно)	Спрощена (агентна)
Бібліотека відкритих сценаріїв	Розгалужена (MoST, LuST)	Відсутня у відкритому доступі	Обмежена
Підтримка форматів (OSM, OpenDRIVE)	Нативна підтримка обох	Через імпорт	OSM (нативно)
Статус розробки	Активна (DLR, GitHub)	Контрольована вендором	Активна (ETH, GitHub)

Аналіз свідчить, що SUMO перевершує аналоги за чотирма критеріями та демонструє рівні з ними показники за двома іншими. Поєднання відкритої ліцензії, нативного Python API для реалізації замкненого циклу навчання (ML-pipeline), наявності верифікованого сценарію MoST та активної підтримки спільноти стало вирішальним для цієї роботи. Як середовище моделювання обрано SUMO [28], а об'єктом дослідження – сценарій MoST [29], що є реалістичною моделлю транспортної мережі Князівства Монако з вираженим ранковим піком навантаження.

Мета і задачі роботи. Метою дослідження є розробка та експериментальне оцінювання імітаційної моделі прогностичної маршрутизації транспортних засобів, яка використовує значення короткострокових прогнозів часу проїзду ребер просторово-часової графової мережі уваги (STGAT) у якості вагових коефіцієнтів для ребер у динамічній перемаршрутизації на основі алгоритму Дейкстри.

Для досягнення мети визначено такі задачі:

1. Проектування архітектури прогностичної маршрутизації: організація потоку даних між симулятором, модулем прогнозування та маршрутизатором.
2. Формалізація дорожньої мережі у вигляді двоїстого графа, а задачі прогнозування – як просторово-часової регресії.
3. Програмна реалізація моделі STGAT-PR (GAT + GRU) та конвеєра маршрутизації в середовищі SUMO із використанням TraCI та PyTorch.
4. Проведення порівняльних імітаційних експериментів для п'яти стратегій маршрутизації за різних рівнів попиту.
5. Статистичний аналіз варіативності середнього часу в дорозі та стабільності маршрутів із перевіркою гіпотез та розрахунком розміру ефекту.

Метрики ефективності системи:

- *основний показник*: середній час у дорозі (MTT);
- *граничні показники*: 95-й перцентиль та максимальний час у дорозі (оцінка критичних затримок).
- *стабільність*: коефіцієнт варіації (CoV) та індекс буферного часу (BTI) ;
- *параметри прийняття рішень*: інтенсивність перемаршрутизації та її питома ефективність (час заощадження на одну подію);
- *пропускна здатність*: частка транспортних засобів, що досягли пункту призначення в межах часового вікна.

Порівняння стратегій здійснювалося за допомогою парного одностороннього t-тесту та знакового рангового тесту Вілкоксона; розмір ефекту оцінювався за статистичним d-коефіцієнтом Коена. Якість прогнозів нейронної моделі оцінювалася окремо за метриками MAE, RMSE, R^2 та MAPE.

Виклад основного матеріалу.

Архітектура системи. Прогностичну систему маршрутизації реалізовано у формі замкненого циклу на базі мікроскопічного симулятора SUMO. Архітектура складається з трьох функціональних модулів, що працюють у режимі реального часу: модуля збору даних (фіксація стану мережі), модуля прогнозування (генерація короткострокових прогнозів часу проїзду ребер) та модуля маршрутизації (застосування прогнозів як вагових коефіцієнтів в алгоритмі Дейкстри з наступним оновленням маршрутів у симуляторі). Схему циклу наведено на рис. 1.

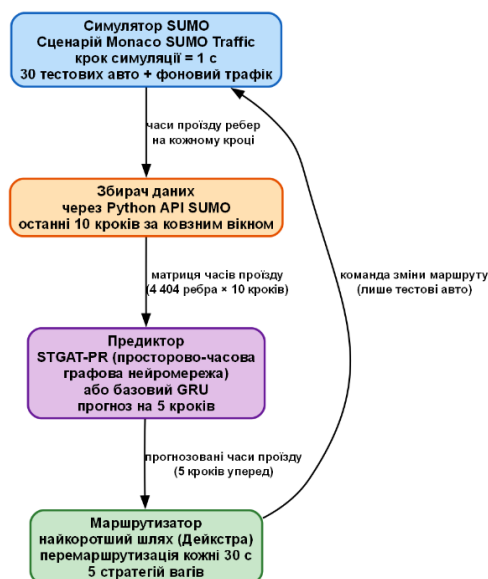


Рис. 1. Замкнений цикл системи прогностичної маршрутизації

На кожному кроці ітерації модуль збору даних через інтерфейс TraCI API отримує актуальні показники тривалості проїзду ребрами та формує ковзне вікно довжиною $H = 10$ кроків. Вікно є вхідним тензором $X \in \mathbb{R}^{(N \times H)}$, де $N = 4\ 404$ – кількість напрямлених ребер у мережі. Модуль прогнозування обробляє X та генерує матрицю $\hat{T} \in \mathbb{R}^{(N \times H)}$ (де $F = 5$), що містить прогнози часу проїзду на наступні п'ять кроків для кожного сегмента. Модуль маршрутизації трансформує \hat{T} у ваги графа, виконує пошук найкоротшого шляху за алгоритмом Дейкстри для кожного транспортного засобу та ініціює команду `traci.vehicle.setRoute` у разі виявлення ефективнішої траєкторії.

Рішення щодо перемаршрутизації приймаються з інтервалом $R = 30$ секунд симуляційного часу. Поза межами циклу рух транспортних засобів визначається стандартними моделями слідування за лідером (*car-following*) та зміни смуги (*lane-changing*), інтегрованими в SUMO. Описаний алгоритм є спільним для всіх п'яти досліджуваних стратегій; варіативність підходів забезпечується зміною функції формування вагових коефіцієнтів. Статична та реактивна стратегії функціонують без залучення модуля прогнозування, тоді як STGAT-PR, абляційна модель GRU-only та гібридно-адаптивна стратегія використовують предиктор у різних конфігураціях.

Просторовий компонент: графова мережа з механізмом уваги (GAT). У межах дуального представлення графа кожне напрямлене ребро мережі MoST інтерпретується як вузол графа прогнозування. Зв'язок між двома вузлами встановлюється за умови конвергенції відповідних дорожніх сегментів у спільному перехресті. Така дуалізація дозволяє моделювати цільову змінну (час проїзду) безпосередньо на рівні вузлів, уникаючи необхідності дегрегації даних про перехрестя. Матриця суміжності $A \in \{0, 1\}^{N \times N}$ дуального графа є статичною та будується на основі топології файлу `.net.xml`.

Для кожного часового кроку $t \in [1, H]$ вхідного вікна шар GAT [11] обчислює контекстно-залежне зважене агрегування ознак сусідніх вузлів. Конфігурація моделі передбачає $K = 4$ голови уваги з прихованою розмірністю $d = 32$ та регуляризацією *dropout* (0,1). Шар GAT оновлює представлення кожного ребра $h(t) \in \mathbb{R}^{N \times d}$. Коефіцієнти уваги навчаються з ознак вузлів на поточному кроці, тому вплив перехрестя, завантаженого нижче за течією потоку може бути математично підсилений відносно порожньої бічної вулиці, а не зважений симетрично, як це характерно для графових згорткових мереж. Вихід $h(t)$ – один тензор на вхідний крок.

Часовий компонент: вентильний рекурентний блок (GRU). Послідовність просторових представлень кожного вузла $[h(1), \dots, h(H)]$ передається на одношаровий блок GRU [12] (вхідна розмірність – 32, прихована – 64) для послідовної обробки часових кроків. Використовуючи вентилі оновлення (*update gate*) та скидання (*reset gate*), GRU компресує часову траєкторію у фінальний прихований стан $h_H \in \mathbb{R}^{N \times 64}$. Цей вектор накопичує просторово-часовий сигнал у межах аналізованого вікна. Вибір архітектури GRU замість LSTM зумовлений традиційною практикою прогнозування трафіку: модель забезпечує аналогічну точність за меншої кількості параметрів, що критично для оптимізації використання відеопам'яті (GPU) при одночасному навчанні на великих масивах ребер.

Потік даних та архітектура моделі. Повний прямий прохід у моделі STGAT-PR реалізовано наступним чином. Вхідний тензор $X \in \mathbb{R}^{N \times H}$ піддається Z-нормалізації для кожного ребра з використанням параметрів масштабування, обчислених на тренувальній вибірці. Для кожного часового кроку t шар GAT обробляє відповідний зріз $X(t) \in \mathbb{R}^N$, генеруючи просторове представлення $h(t) \in \mathbb{R}^{N \times d}$. Отримані H представлень упорядковуються у часову послідовність для кожного вузла та передаються в блок GRU. Фінальний прихований стан GRU трансформується лінійним шаром із матрицею ваг $W \in \mathbb{R}^{F \times 64}$ у прогнозний вектор $\hat{T} \in \mathbb{R}^{N \times F}$. Перед передачею в модуль маршрутизації результати піддаються денормалізації для відновлення вихідної шкали часу проїзду. Повну архітектуру системи представлено на рис. 2.

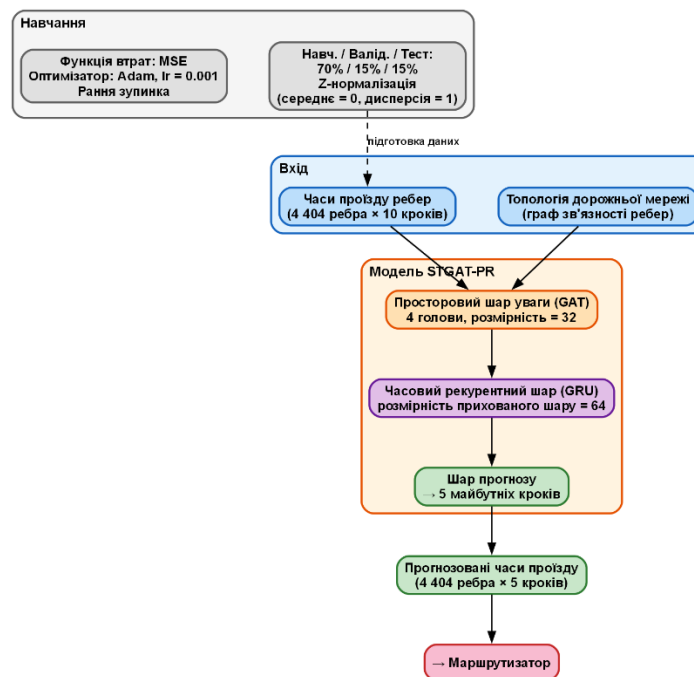


Рис. 2. Архітектура STGAT-PR: просторова графова мережа з механізмом уваги (GAT), часовий вентиляльний рекурентний блок (GRU) та лінійна прогнозна голова з конфігурацією навчання

Процедура навчання. Навчання моделі проводилося в автономному режимі на наборі даних, отриманих шляхом симуляції при значенні $DEMAND_SCALE = 1,0$ із трьома незалежними початковими значеннями. Датасет розподілено за часовим принципом у пропорції 70/15/15 для тренувальної, валідаційної та тестової вибірок відповідно, що дозволило уникнути витоку даних на межах ітерацій.

Для оптимізації використовувався алгоритм Adam із кроком навчання $1e-3$. Розмір батча становив 8 для STGAT-PR (зумовлено обмеженням відеопам'яті обсягом 4 ГБ) та 64 для абляційної моделі GRU-only. Навчання тривало до 50 епох із застосуванням критерію ранньої зупинки за валідаційною втратою (період очікування – 10 епох). Як функцію втрат обрано середньоквадратичну похибку щодо фактичних показників часу проїзду. Отримані параметри моделі та коефіцієнти масштабування використовувалися без змін у всіх експериментальних сценаріях, включаючи стрес-тест при $DEMAND_SCALE = 1,2$.

Модуль маршрутизації та стратегії оновлення ваг. Модуль маршрутизації використовує прогностичні (або, для базових стратегій, виміряні чи вільнопотокові) значення ваг ребер для ітераційного пошуку найкоротшого шляху за алгоритмом Дейкстри [8]. Маршрут транспортного засобу оновлюється лише у разі виявлення траєкторії, ефективнішої за поточну. Алгоритм керування представлено на рис. 3.

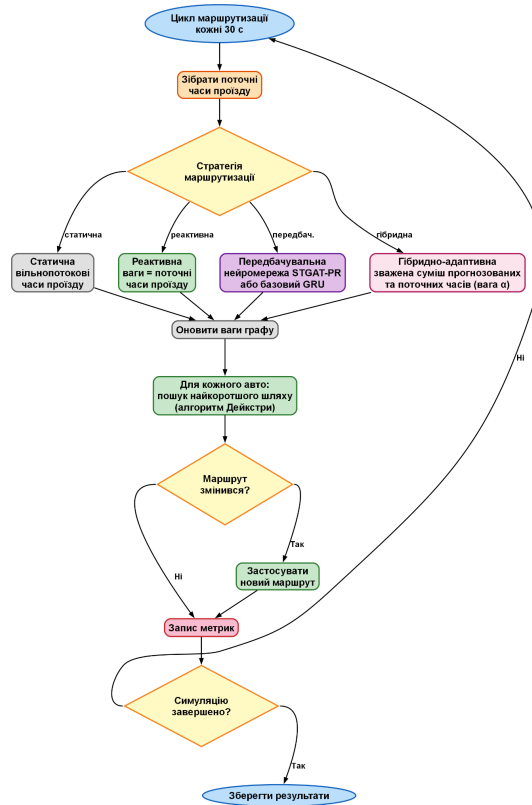


Рис. 3. Блок-схема модуля маршрутизації з механізмами адаптації ваг

У дослідженні порівнюються п'ять стратегій маршрутизації, що різняться виключно методом обчислення вагових коефіцієнтів ребер:

- *статична*: ваги відповідають часу проїзду у вільному потоці ($length / max_speed$). Перемаршрутизація у відповідь на зміну трафіку не проводиться (це базова лінія без маршрутизації).
- *реактивна*: ваги формуються на основі поточних вимірювань $T(t)$, зчитаних з TraCI. Маршрутизатор реагує на затори, що вже сформувалися.
- *STGAT-PR*: ваги базуються на прогнозованих значеннях $\hat{T}(t + F)$, згенерованих повною моделлю GAT+GRU.
- *GRU-only*: маршрутизація співпадає з STGAT-PR, але шар GAT замінено на спрощений просторовий оператор. Дозволяє ізолювати вплив механізму просторової уваги.
- *гібридно-адаптивна*: ваги обчислюються як опукла комбінація прогнозованих та актуальних значень: $\alpha \cdot \hat{T}(t + F) + (1 - \alpha) \cdot T(t)$. Коефіцієнт $\alpha = f(CI)$ варіюється в діапазоні $[0,5; 0,8]$, де CI – індекс завантаженості мережі в цілому, обчислений як середнє відношення поточного до вільнопотокового часу проїзду по активних ребрах.

Обґрунтування вибору алгоритму пошуку. Вибір алгоритму Дейкстри замість алгоритму A^* [9] зумовлений топологічними особливостями міських транспортних мереж. На мережі з одностороннім рухом та обмеженнями поворотів евклідова евристика не може надійно недооцінювати справжню вагу шляху на графі, що зводить до нуля перевагу алгоритму A^* по швидкості над алгоритмом Дейкстри. Крім того, обчислювальна складність одного запиту за алгоритмом Дейкстри в даній мережі становить кілька мілісекунд, що є несуттєвим порівняно з витратами симулятора на розрахунок фізики руху. Оскільки маршрутизація потребує незначних часових витрат, перехід на швидший алгоритм A^* не дає на практиці помітного виграшу в продуктивності системи, тому алгоритм Дейкстри збережений для всіх п'яти стратегій.

Сценарій та параметри попиту. Емпіричною базою дослідження слугує сценарій MoST (*Monaco SUMO Traffic*) [29] – деталізована імітаційна модель транспортної мережі Князівства Монако, що складається з 4404 напрямлених ребер. Фоновий трафік генерується на основі оригінального профілю попиту MoST, який охоплює близько 47 000 поїздок, розподілених протягом

добі, з яскраво вираженим ранковим піком. Часове вікно симуляції (04:00 – 10:00) обрано для охоплення повного циклу: від наростання пікового навантаження до його поступового розсіювання.

Для моделювання різних рівнів завантаження мережі до фонових потоків рівномірно застосовується коефіцієнт масштабування *DEMAND_SCALE*. В експериментах оцінено два сценарії:

- *DEMAND_SCALE* = 1.0 – базове ранкове пікове навантаження;
- *DEMAND_SCALE* = 1.2 – стрес-тест із підвищенням попиту на 20% відносно базового рівня.

Модуль прогнозування не проходив донавчання для стрес-тесту. Ті самі вагові коефіцієнти моделі, що навчені і оптимізовані за умов *DEMAND_SCALE* = 1.0, використовуються без змін, це дозволяє оцінити здатність моделі до узагальнення при невідомих рівнях навантаження.

Оцінка ефективності здійснюється на цільовій вибірці з 30 керованих тестових транспортних засобів, які маршрутизуються в межах замкненого циклу, тоді як фоновий трафік рухається за статичними маршрутами базового попиту. Тестові автомобілі вводяться в мережу о 07:00 за місцевим часом із фіксованими парами «походження – призначення» (O-D парами), які поділено на дві категорії:

- маршрути середньої дальності (14 пар);
- маршрути великої дальності (16 пар).

Тестові транспортні засоби взаємодіють із фоновим потоком у спільному середовищі згідно зі стандартними моделями слідування за лідером (*car-following*) та зміни смуги (*lane-changing*). Усі наведені нижче метрики продуктивності розраховані виключно для цільової тестової вибірки.

Проведення експерименту та результати. Для кожної з 10 експериментальних конфігурацій (5 стратегій × 2 рівні попиту) виконано 20 незалежних ітерацій симуляції з різними початковими значеннями генератора псевдовипадкових чисел, що загалом становить 200 прогонів. Агреговані результати наведено в табл. 2.

Таблиця 2. Результати симуляції: ефективність п'яти стратегій маршрутизації за двох рівнів попиту (середні значення за 20 ітераціями)

Стратегія	MTT, с	std, с	p95, с	max, с	CoV	ВТІ	Кількість пересек- рувань на авто	Час на перемаршру- тизацію (сек.)
DEMAND_SCALE = 1.0								
Статична	733.2	465.1	1 684.0	2 695	0.634	1.761	0.0	0.000
Реактивна	671.6	418.8	1 330.8	3 202	0.624	1.216	165.6	0.372
GRU-only	688.9	410.4	1 487.2	2 929	0.596	1.385	87.0	0.509
STGAT-PR	663.7	368.8	1 368.2	2 319	0.556	1.247	102.0	0.681
Гібридно- адаптивна	670.1	392.1	1 368.2	2 956	0.585	1.275	126.5	0.498
DEMAND_SCALE = 1.2								
Статична	799.1	544.7	1 969.2	3 258	0.682	2.004	0.0	0.000
Реактивна	751.4	464.6	1 633.5	3 720	0.618	1.507	184.9	0.258
GRU-only	757.4	462.5	1 648.0	2 909	0.611	1.530	89.2	0.468
STGAT-PR	717.0	416.3	1 459.1	2 883	0.581	1.266	111.8	0.735
Гібридно- адаптивна	769.6	536.0	1 772.2	6 213	0.696	1.714	143.2	0.209

За умов базового попиту всі динамічні стратегії маршрутизації демонструють вищу ефективність порівняно зі статичною базовою лінією. Стратегія STGAT-PR забезпечує найкращі показники продуктивності: мінімальний середній час поїздки (MTT = 663.7 с) та найнижчий коефіцієнт варіації (CoV = 0.556), що свідчить про найвищу стабільність маршрутів. Кожне рішення з перемаршрутизації в алгоритмі STGAT-PR скорочує час поїздки в середньому на 0.681 с відносно статичної стратегії.

Ефективність реактивного підходу досягається переважно за рахунок інтенсивності втручань, а не їхньої предиктивної точності: система генерує на 60% більше оновлень маршруту на один автомобіль порівняно зі STGAT-PR (165.6 проти 102.0 відповідно), проте середнє скорочення

часу на одну ітерацію становить лише 0.372 с. Гібридно-адаптивна стратегія демонструє проміжні результати за більшістю наведених метрик.

В умовах стрес-тесту ієрархія ефективності стратегій зберігається зі збільшенням дисперсії результатів. Стратегія STGAT-PR демонструє найвищу продуктивність: середній час поїздки (МТТ) становить 717.0 с, що на 10.3 % менше порівняно зі статичною базовою лінією. Показники 95-го перцентилля ($p_{95} = 1459,1$ с) та коефіцієнта варіації ($CoV = 0.581$) залишаються мінімальними серед досліджуваних методів.

Ефективність реактивної стратегії за підвищеного навантаження знижується. Показник МТТ зростає з 671.6 с до 751.4 с, а відносне скорочення часу поїздки порівняно зі статичною стратегією зменшується з 8.4 % до 6.0 %. Ефективність одиначної перемаршрутизації падає з 0.372 с до 0.258 с, попри збільшення частоти втручань до 184.9 на один транспортний засіб.

Натомість STGAT-PR демонструє протилежну тенденцію: ефективність однієї ітерації перемаршрутизації зростає з 0.681 с до 0.735 с. Це свідчить про підвищення цінності прогностичного модуля саме в умовах високого завантаження мережі.

Гібридно-адаптивна стратегія виявилася найвразливішою до стрес-тесту. Її МТТ (769.6 с) перевищує показник реактивної стратегії, а максимальний час поїздки в одній з ітерацій досяг 6213 с, що більше ніж у два рази перевищує найгірший результат STGAT-PR (2883 с).

Статистична значущість результатів. Для перевірки статистичної значущості відмінностей між стратегіями застосовано парні односторонні t-критерії Стьюдента та W-критерій Вілкоксона для зв'язаних вибірок. У табл. 3 наведено розраховані р-значення та показники d Коена для оцінки розміру ефекту.

Таблиця 3. Парне статистичне порівняння стратегій маршрутизації

Порівняння	Δ МТТ, с	Δ МТТ, %	t, с	p (t-тест)	p (Вілкоксон)	d Коена	знач. ($\alpha = 0.05$)
DEMAND SCALE = 1.0							
STGAT-PR vs Реактивна	-7.85	-1.17	-0.597	0.279	0.420	-0.133	ні
STGAT-PR vs GRU-only	-25.13	-3.65	-1.784	0.090	0.064	-0.399	ні
STGAT-PR vs Статична	-69.43	-9.47	-5.766	<0.001	<0.001	-1.289	так
Реактивна vs Статична	-61.57	-8.40	-6.381	<0.001	<0.001	-1.427	так
Гібридно- адапт. vs Реактивна	-1.46	-0.22	-0.147	0.442	0.392	-0.033	ні
DEMAND SCALE = 1.2							
STGAT-PR vs Реактивна	-34.38	-4.58	-2.688	0.007	0.005	-0.601	так
STGAT-PR vs GRU-only	-40.45	-5.34	-3.193	0.005	0.007	-0.714	так
STGAT-PR vs Статична	-82.17	-10.28	-4.087	<0.001	<0.001	-0.914	так
Реактивна vs Статична	-47.79	-5.98	-2.543	0.010	0.005	-0.569	так
Гібридно- адапт. vs Реактивна	+17.88	+2.38	+0.802	0.784	0.689	+0.179	ні

Аналіз результатів дозволяє виділити дві ключові закономірності:

1. За умов базового попиту ($n = 20$) статистично значущої переваги прогностичного підходу не виявлено. Порівняння STGAT-PR із реактивною стратегією демонструє $p = 0.279$ із незначним розміром ефекту ($d = -0.133$), що перебуває в межах статистичної похибки вибірки.

2. В умовах стрес-тесту аналогічне порівняння набуває статистичної значущості із середнім розміром ефекту ($p = 0.007$; $d = -0.601$). Результати абляційного аналізу підтверджують, що це покращення зумовлене механізмом просторової уваги: перевага STGAT-PR над базою GRU-only є значущою за високого навантаження ($p = 0.005$; $d = -0.714$), але статистично відсутня на базовому рівні ($p = 0.090$).

Гібридно-адаптивна стратегія не демонструє статистично значущих переваг над реактивною за жодного зі сценаріїв $p = 0.442$ при DEMAND_SCALE = 1.0; $p = 0.784$ при DEMAND_SCALE = 1.2). Під час стрес-тесту гібридно-адаптивна схема поступається реактивному підходу на 2.4 % у середньому вимірі. Це узгоджується з ефектом насичення її адаптивного правила α -CI на верхній межі ($\alpha = 0.8$) у випадках, коли рівень завантаженості перевищує діапазон калібрування.

Якість прогнозування та генералізація. Якість роботи нейромережових моделей в умовах симуляції наведено в табл. 4. Оцінювання метрик здійснювалося для кожного ребра на основі всіх прогнозів, згенерованих під час ітерацій відповідної стратегії.

Таблиця 4. Метрики якості прогнозування нейромережових моделей у симуляційному середовищі за двох рівнів попиту

Модель	MAE, с	RMSE, с	R ²	MAPE, %	Кількість прогнозів
DEMAND_SCALE = 1.0					
STGAT-PR	1.066	5.148	0.915	8.85	2 170 262
GRU-only	1.110	5.268	0.911	8.70	2 466 323
Гібридно-адаптивна	1.069	5.200	0.913	8.81	2 383 160
DEMAND_SCALE = 1.2					
STGAT-PR	1.168	5.612	0.906	9.16	2 610 963
GRU-only	1.220	5.728	0.902	8.97	2 750 512
Гібридно-адаптивна	1.265	6.007	0.900	9.57	3 936 338

Модуль прогнозування, навчений за умов DEMAND_SCALE = 1.0, зберігає високий коефіцієнт детермінації ($R^2 = 0.906$) при DEMAND_SCALE = 1.2 без донавчання (зниження становить лише 0.009 порівняно з базовим розподілом). Показник MAPE зростає з 8.85 % до 9.16 % (+0.31 в. п.), а MAE – з 1.066 с до 1.168 с. Це підтверджує здатність моделі до генералізації на невідомих рівнях навантаження. Таким чином, ефективність системи за підвищеного попиту підтверджує стійкість запропонованої архітектури, а не є наслідком перенавчання на тренувальних даних.

Висновки. У міських транспортних мережах реактивна маршрутизація реагує на вже сформовані затори, що критично знижує її ефективність в умовах стрімкого зростання попиту. Для подолання цього обмеження розроблено імітаційну модель із замкненим циклом, у якій просторово-часова графова мережа уваги STGAT-PR (поєднує в собі архітектури GAT та GRU) генерує прогнози часу проїзду ребер транспортної мережі на п'ять кроків уперед. Ці прогнози інтегруються як вагові коефіцієнти в алгоритм Дейкстри для індивідуальної перемаршрутизації транспортних засобів із 30-секундним інтервалом. Ефективність моделі валідовано на мікроскопічному сценарії MoST у середовищі SUMO шляхом порівняння п'яти стратегій за двох рівнів попиту (загалом 200 симуляційних прогонів).

За умов базового попиту стратегія STGAT-PR продемонструвала мінімальний середній час поїздки (663.7 с) та найнижчий коефіцієнт варіації (0.556). Однак її перевага над реактивною стратегією виявилася статистично незначущою ($p = 0.279$; $d = -0.133$). В умовах стрес-тесту (+20 % попиту) STGAT-PR забезпечила скорочення середнього часу поїздки на 34.4 с (-4.6 %) порівняно з реактивним підходом. Цей результат є статистично значущим із середнім розміром ефекту (парний t-критерій $p = 0.007$; критерій Вілксона $p = 0.005$; d Коена = -0.601). Абляційний аналіз порівняно з базою GRU-only також підтвердив статистичну значущість за високого навантаження (-5.3%; $p = 0.005$; $d = -0.714$), що доводить ключову роль механізму просторової уваги. Гібридно-адаптивна схема не перевершила реактивну стратегію під час стрес-тесту (+2.4 %; $p = 0.784$), що пояснюється ефектом насичення її адаптивного правила α -CI за межами діапазону калібрування.

Наукова новизна роботи полягає в безпосередній інтеграції прогнозів просторово-часової графової моделі з механізмом уваги у вагові коефіцієнти алгоритму Дейкстри в межах глобального

циклу мікроскопічного моделювання. Статистично доведено, що такий підхід зменшує середній час поїздки та підвищує стабільність маршрутів за умов високого попиту без необхідності перенавчання модуля.

Практичне застосування розробленої імітаційної моделі дозволяє:

- здійснювати кількісне порівняння стратегій маршрутизації перед їхнім упровадженням;
- визначати порогові значення попиту, за яких предиктивний підхід стає логістично виправданим;
- проводити аналіз чутливості ефективності маршрутизації до точності прогнозування;
- обґрунтовувати проєктні рішення під час розроблення модулів керування трафіком у системах «розумного міста».

Перспективи подальших досліджень. Майбутні дослідження у напрямі прогностичної маршрутизації доцільно зосередити на:

- удосконаленні гібридно-адаптивної схеми для запобігання насиченню коефіцієнта α за екстремальних рівнів завантаженості;
- оцінюванні здатності навченої моделі до перенесення на топологічні структури інших міст (наприклад, Кельн, Інгольштадт);
- впровадженні алгоритмів потокового донавчання модуля прогнозування в режимі реального часу;
- реалізації багатокритеріальної оптимізації маршрутів із врахуванням мінімізації енергоспоживання та уникнення аномальних затримок (випадків).

Список бібліографічного опису

1. INRIX. 2024 Global Traffic Scorecard: London most congested city in Europe; congestion costing the UK £7.7 billion. 2025. URL: <https://inrix.com/press-releases/2024-global-traffic-scorecard-uk/> (дата звернення: 15.05.2026).
2. Güven G. Telework-induced urban sprawl and traffic congestion: a social discount rate analysis. *European Transport Research Review*. 2025. Vol. 17. Art. 44. DOI: <https://doi.org/10.1186/s12544-025-00730-z>.
3. Blumenfeld E., Serok N., Duan J., Zeng G., Havlin S. Addressing the urban congestion challenge based on traffic bottlenecks. *Philosophical Transactions of the Royal Society A*. 2024. Vol. 382, Iss. 2285. Art. 20240095. DOI: <https://doi.org/10.1098/rsta.2024.0095>.
4. TomTom Traffic Index — Annual Ranking 2024 : company report / TomTom International B.V. 2025. URL: <https://www.tomtom.com/traffic-index/ranking/> (дата звернення: 15.05.2026).
5. Directive 2010/40/EU of the European Parliament and of the Council of 7 July 2010 on the framework for the deployment of Intelligent Transport Systems in the field of road transport and for interfaces with other modes of transport. *Official Journal of the European Union*. 2010. L 207. P. 1–13. URL: <https://eur-lex.europa.eu/eli/dir/2010/40/oj> (дата звернення: 15.05.2026).
6. Puzio E., Kolon M., Drożdż W. The role of intelligent transport systems and smart technologies in urban traffic management in Polish smart cities. *Energies*. 2025. Vol. 18, Iss. 10. Art. 2580. DOI: <https://doi.org/10.3390/en18102580>.
7. Cordoş N., Duma A., Moldovanu D., Todoruţ A., Barabás I. An overview of intelligent transportation systems in Europe. *World Electric Vehicle Journal*. 2025. Vol. 16, Iss. 7. Art. 387. DOI: <https://doi.org/10.3390/wevj16070387>.
8. Dijkstra E. W. A note on two problems in connexion with graphs. *Numerische Mathematik*. 1959. Vol. 1. P. 269–271. DOI: <https://doi.org/10.1007/BF01386390>.
9. Hart P. E., Nilsson N. J., Raphael B. A formal basis for the heuristic determination of minimum cost paths. *IEEE Transactions on Systems Science and Cybernetics*. 1968. Vol. 4, Iss. 2. P. 100–107. DOI: <https://doi.org/10.1109/TSSC.1968.300136>.
10. Wang C., Atkison T., Park H. Dynamic adaptive vehicle re-routing strategy for traffic congestion mitigation of grid network. *International Journal of Transportation Science and Technology*. 2024. Vol. 14. P. 120–136. DOI: <https://doi.org/10.1016/j.ijst.2023.04.003>.
11. Veličković P., Cucurull G., Casanova A., Romero A., Liò P., Bengio Y. Graph attention networks. *Proc. International Conference on Learning Representations (ICLR)*. 2018. DOI: <https://doi.org/10.17863/CAM.48429>.
12. Cho K., van Merriënboer B., Gulcehre C., Bahdanau D., Bougares F., Schwenk H., Bengio Y. Learning phrase representations using RNN encoder–decoder for statistical machine translation. *Proc. 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha, 2014. P. 1724–1734. DOI: <https://doi.org/10.3115/v1/D14-1179>.
13. Zhao L., Song Y., Zhang C., Liu Y., Wang P., Lin T. et al. T-GCN: A temporal graph convolutional network for traffic prediction. *IEEE Transactions on Intelligent Transportation Systems*. 2020. Vol. 21, Iss. 9. P. 3848–3858. DOI: <https://doi.org/10.1109/TITS.2019.2935152>.
14. Zhao W., Zhang S., Wang B., Zhou B. Spatio-temporal causal graph attention network for traffic flow prediction in intelligent transportation systems. *PeerJ Computer Science*. 2023. Vol. 9. Art. e1484. DOI: <https://doi.org/10.7717/peerj-cs.1484>.
15. Chen Y., Huang J., Xu H., Guo J., Su L. Road traffic flow prediction based on dynamic spatiotemporal graph attention network. *Scientific Reports*. 2023. Vol. 13. Art. 14729. DOI: <https://doi.org/10.1038/s41598-023-41932-6>.
16. Adamenko A. N., Asherov A. T., Berdnikov I. L. Information Controlling Human-Machine Systems: Research, Design, Testing. Reference Book / ed. by A. I. Gubinsky, V. G. Evgrafov. Mashinostroenie, 1993.

17. Lavrov E., Pasko N. Development of Models for Computer Systems of Processing Information and Control for Tasks of Ergonomic Improvements. *Commun. Comput. Inf. Sci. (ICIST 2018)*. Cham : Springer, 2018. Vol. 920. DOI: https://doi.org/10.1007/978-3-319-99972-2_8.
18. Lavrov E., Paderno P., Siryk O., Burkov E., Pasko N., Nahorni V. Decision Support in Incident Management Systems. Models of Searching for Ergonomic Reserves to Increase Efficiency. *2020 IEEE International Conference on Problems of Infocommunications. Science and Technology (PIC S&T)*. Kharkiv, 2020. P. 653–658. DOI: <https://doi.org/10.1109/PICST51311.2020.9467991>.
19. Лавров Є., Чибіряк Я., Сірик О., Великодний Д., Боровик В. Підхід до побудови автоматизованих систем експертного оцінювання для підтримки прийняття стратегічних і тактичних рішень. *Комп'ютерно-інтегровані технології: освіта, наука, виробництво*. 2023. № 52. С. 10–23. DOI: <https://doi.org/10.36910/6775-2524-0560-2023-52-02>.
20. Чибіряк Я., Захарова А., Лавров Є., Великодний Д., Боровик В. Моделі для автоматизованого пошуку раціональних варіантів компонування виробів машинобудування. *Комп'ютерно-інтегровані технології: освіта, наука, виробництво*. 2023. № 52. С. 32–42. DOI: <https://doi.org/10.36910/6775-2524-0560-2023-52-04>.
21. Чибіряк Я., Баранова І., Ніколаєнко К. Метод наскрізного навчання студентів ІТ-спеціальностей імітаційному моделюванню у середовищі FlexSim для пошуку резервів підвищення ефективності автоматизованих систем. *KIT*. 2021. Вип. 42. С. 119–129.
22. Чибіряк Я., Захарова А., Лавров Є., Сірик О., Баранова І., Татарчук Р. Комп'ютерне моделювання для медицини катастроф. Підхід до автоматизованого аналізу рішень з організації мобільних медичних шпиталів. *Комп'ютерно-інтегровані технології: освіта, наука, виробництво*. 2024. № 55. С. 232–242. DOI: <https://doi.org/10.36910/6775-2524-0560-2024-55-29>.
23. Чибіряк Я. І., Овчаренко К. В., Ніколаєнко К. О. Імітаційна модель функціонування мережі зв'язку. *Інформатика, математика, механіка : матеріали та програма науково-технічної конференції* (м. Суми, 20–25 квітня 2021 р.). Суми : СумДУ, 2021. С. 150–151.
24. Чибіряк Я. І., Устименко К. О., Захарова А. М. Розробка імітаційної моделі локальної обчислювальної мережі. *Інформатика, математика, механіка : матеріали та програма науково-технічної конференції* (м. Суми, 20–25 квітня 2023 р.). Суми : СумДУ, 2023. С. 228.
25. Storani F., Di Pace R., Bruno F., Fiori C. Analysis and comparison of traffic flow models: a new hybrid traffic flow model vs benchmark models. *European Transport Research Review*. 2021. Vol. 13. Art. 58. DOI: <https://doi.org/10.1186/s12544-021-00515-0>.
26. Anyin P., Wittenberg D., Pannek J. Quantitative methodology for comparing microscopic traffic simulators. *Future Transportation*. 2025. Vol. 5, Iss. 4. Art. 201. DOI: <https://doi.org/10.3390/futuretransp5040201>.
27. Diallo A. O., Lozenguez G., Doniec A., Mandiau R. Comparative evaluation of road traffic simulators based on modeler's specifications: an application to intermodal mobility behaviors. *Proc. 13th International Conference on Agents and Artificial Intelligence (ICAART)*. 2021. P. 265–272. DOI: <https://doi.org/10.5220/0010238302650272>.
28. Lopez P. A., Behrisch M., Bieker-Walz L., Erdmann J., Flötteröd Y.-P., Hilbrich R. et al. Microscopic traffic simulation using SUMO. *Proc. 2018 21st IEEE International Conference on Intelligent Transportation Systems (ITSC)*. Maui, 2018. P. 2575–2582. DOI: <https://doi.org/10.1109/ITSC.2018.8569938>.
29. Codeca L., Härrı J. Towards multimodal mobility simulation of C-ITS: the Monaco SUMO traffic scenario. *Proc. 2017 IEEE Vehicular Networking Conference (VNC)*. Turin, 2017. P. 97–100. DOI: <https://doi.org/10.1109/VNC.2017.8275627>.

References

1. INRIX. 2024 Global Traffic Scorecard: London most congested city in Europe; congestion costing the UK £7.7 billion. 2025. URL: <https://inrix.com/press-releases/2024-global-traffic-scorecard-uk/> (accessed: 15.05.2026).
2. Güven G. Telework-induced urban sprawl and traffic congestion: a social discount rate analysis. *European Transport Research Review*. 2025. Vol. 17. Art. 44. DOI: <https://doi.org/10.1186/s12544-025-00730-z>.
3. Blumenfeld E., Serok N., Duan J., Zeng G., Havlin S. Addressing the urban congestion challenge based on traffic bottlenecks. *Philosophical Transactions of the Royal Society A*. 2024. Vol. 382, Iss. 2285. Art. 20240095. DOI: <https://doi.org/10.1098/rsta.2024.0095>.
4. TomTom Traffic Index — Annual Ranking 2024 : company report / TomTom International B.V. 2025. URL: <https://www.tomtom.com/traffic-index/ranking/> (accessed: 15.05.2026).
5. Directive 2010/40/EU of the European Parliament and of the Council of 7 July 2010 on the framework for the deployment of Intelligent Transport Systems in the field of road transport and for interfaces with other modes of transport. *Official Journal of the European Union*. 2010. L 207. P. 1–13. URL: <https://eur-lex.europa.eu/eli/dir/2010/40/oj> (accessed: 15.05.2026).
6. Puzio E., Kolon M., Drożdż W. The role of intelligent transport systems and smart technologies in urban traffic management in Polish smart cities. *Energies*. 2025. Vol. 18, Iss. 10. Art. 2580. DOI: <https://doi.org/10.3390/en18102580>.
7. Cordoş N., Duma A., Moldovanu D., Todoruţ A., Barabás I. An overview of intelligent transportation systems in Europe. *World Electric Vehicle Journal*. 2025. Vol. 16, Iss. 7. Art. 387. DOI: <https://doi.org/10.3390/wevj16070387>.
8. Dijkstra E. W. A note on two problems in connexion with graphs. *Numerische Mathematik*. 1959. Vol. 1. P. 269–271. DOI: <https://doi.org/10.1007/BF01386390>.
9. Hart P. E., Nilsson N. J., Raphael B. A formal basis for the heuristic determination of minimum cost paths. *IEEE Transactions on Systems Science and Cybernetics*. 1968. Vol. 4, Iss. 2. P. 100–107. DOI: <https://doi.org/10.1109/TSSC.1968.300136>.
10. Wang C., Atkison T., Park H. Dynamic adaptive vehicle re-routing strategy for traffic congestion mitigation of grid network. *International Journal of Transportation Science and Technology*. 2024. Vol. 14. P. 120–136. DOI: <https://doi.org/10.1016/j.ijtst.2023.04.003>.

11. Veličković P., Cucurull G., Casanova A., Romero A., Liò P., Bengio Y. Graph attention networks. *Proc. International Conference on Learning Representations (ICLR)*. 2018. DOI: <https://doi.org/10.17863/CAM.48429>.
12. Cho K., van Merriënboer B., Gulcehre C., Bahdanau D., Bougares F., Schwenk H., Bengio Y. Learning phrase representations using RNN encoder–decoder for statistical machine translation. *Proc. 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha, 2014. P. 1724–1734. DOI: <https://doi.org/10.3115/v1/D14-1179>.
13. Zhao L., Song Y., Zhang C., Liu Y., Wang P., Lin T. et al. T-GCN: A temporal graph convolutional network for traffic prediction. *IEEE Transactions on Intelligent Transportation Systems*. 2020. Vol. 21, Iss. 9. P. 3848–3858. DOI: <https://doi.org/10.1109/TITS.2019.2935152>.
14. Zhao W., Zhang S., Wang B., Zhou B. Spatio-temporal causal graph attention network for traffic flow prediction in intelligent transportation systems. *PeerJ Computer Science*. 2023. Vol. 9. Art. e1484. DOI: <https://doi.org/10.7717/peerj-cs.1484>.
15. Chen Y., Huang J., Xu H., Guo J., Su L. Road traffic flow prediction based on dynamic spatiotemporal graph attention network. *Scientific Reports*. 2023. Vol. 13. Art. 14729. DOI: <https://doi.org/10.1038/s41598-023-41932-6>.
16. Adamenko A. N., Asherov A. T., Berdnikov I. L. *Information Controlling Human-Machine Systems: Research, Design, Testing. Reference Book* / ed. by A. I. Gubinsky, V. G. Evgrafov. Mashinostroenie, 1993.
17. Lavrov E., Pasko N. Development of Models for Computer Systems of Processing Information and Control for Tasks of Ergonomic Improvements. *Commun. Comput. Inf. Sci. (ICIST 2018)*. Cham : Springer, 2018. Vol. 920. DOI: https://doi.org/10.1007/978-3-319-99972-2_8.
18. Lavrov E., Paderno P., Siryk O., Burkov E., Pasko N., Nahornyi V. Decision Support in Incident Management Systems. Models of Searching for Ergonomic Reserves to Increase Efficiency. *2020 IEEE International Conference on Problems of Infocommunications. Science and Technology (PIC S&T)*. Kharkiv, 2020. P. 653–658. DOI: <https://doi.org/10.1109/PICST51311.2020.9467991>.
19. Lavrov Ye., Chybiriak Ya., Siryk O., Velykodnyi D., Borovyk V. Pidkhid do pobudovy avtomatyzovanykh system ekspertnoho otsiniuvannia dlia pidtrymky pryiniattia stratehichnykh i taktychnykh rishen [Approach to building automated systems of expert evaluation to support the making of strategic and tactical decisions]. *Kompiuterno-intehrovani tekhnologii: osvita, nauka, vyrobnytstvo*. 2023. No. 52. P. 10–23. DOI: <https://doi.org/10.36910/6775-2524-0560-2023-52-02>. [in Ukrainian].
20. Chybiriak Ya., Zakharova A., Lavrov Ye., Velykodnyi D., Borovyk V. Modeli dlia avtomatyzovanoho poshuku ratsionalnykh variantiv komponuvannia vyrobiv mashynobuduvannia [Models for automated search of rational options for layout of mechanical engineering products]. *Kompiuterno-intehrovani tekhnologii: osvita, nauka, vyrobnytstvo*. 2023. No. 52. P. 32–42. DOI: <https://doi.org/10.36910/6775-2524-0560-2023-52-04>. [in Ukrainian].
21. Chybiriak Ya., Baranova I., Nikolaienko K. Metod naskriznogo navchannia studentiv IT-spetsialnostei imitatsiinomu modeliuvanniu u seredovyshchi FlexSim dlia poshuku rezerviv pidvyshchennia efektyvnosti avtomatyzovanykh system [Method of end-to-end training of IT students in simulation modeling in the FlexSim environment to find reserves for improving the efficiency of automated systems]. *KIT*. 2021. Iss. 42. P. 119–129. [in Ukrainian].
22. Chybiriak Ya., Zakharova A., Lavrov Ye., Siryk O., Baranova I., Tatarchuk R. Kompiuterne modeliuvannia dlia medytsyny katastrof. Pidkhid do avtomatyzovanoho analizu rishen z orhanizatsii mobilnykh medychnykh shpytaliv [Computer modeling for disaster medicine. Approach to automated analysis of decisions on the organization of mobile medical hospitals]. *Kompiuterno-intehrovani tekhnologii: osvita, nauka, vyrobnytstvo*. 2024. No. 55. P. 232–242. DOI: <https://doi.org/10.36910/6775-2524-0560-2024-55-29>. [in Ukrainian].
23. Chybiriak Ya. I., Ovcharenko K. V., Nikolaienko K. O. Imitatsiina model funktsionuvannia merezhi zviazku [Simulation model of communication network functioning]. *Informatyka, matematyka, mekhanika : materialy ta prohrama naukovo-tekhnichnoi konferentsii* (Sumy, April 20–25, 2021). Sumy : SumDU, 2021. P. 150–151. [in Ukrainian].
24. Chybiriak Ya. I., Ustymenko K. O., Zakharova A. M. Rozrobka imitatsiinoi modeli lokalnoi obchysluvalnoi merezhi [Development of a simulation model of a local area network]. *Informatyka, matematyka, mekhanika : materialy ta prohrama naukovo-tekhnichnoi konferentsii* (Sumy, April 20–25, 2023). Sumy : SumDU, 2023. P. 228. [in Ukrainian].
25. Storani F., Di Pace R., Bruno F., Fiori C. Analysis and comparison of traffic flow models: a new hybrid traffic flow model vs benchmark models. *European Transport Research Review*. 2021. Vol. 13. Art. 58. DOI: <https://doi.org/10.1186/s12544-021-00515-0>.
26. Anyin P., Wittenberg D., Pannek J. Quantitative methodology for comparing microscopic traffic simulators. *Future Transportation*. 2025. Vol. 5, Iss. 4. Art. 201. DOI: <https://doi.org/10.3390/futuretransp5040201>.
27. Diallo A. O., Lozenguez G., Doniec A., Mandiau R. Comparative evaluation of road traffic simulators based on modeler's specifications: an application to intermodal mobility behaviors. *Proc. 13th International Conference on Agents and Artificial Intelligence (ICAART)*. 2021. P. 265–272. DOI: <https://doi.org/10.5220/0010238302650272>.
28. Lopez P. A., Behrisch M., Bieker-Walz L., Erdmann J., Flötteröd Y.-P., Hilbrich R. et al. Microscopic traffic simulation using SUMO. *Proc. 2018 21st IEEE International Conference on Intelligent Transportation Systems (ITSC)*. Maui, 2018. P. 2575–2582. DOI: <https://doi.org/10.1109/ITSC.2018.8569938>.
29. Codeca L., Härrilä J. Towards multimodal mobility simulation of C-ITS: the Monaco SUMO traffic scenario. *Proc. 2017 IEEE Vehicular Networking Conference (VNC)*. Turin, 2017. P. 97–100. DOI: <https://doi.org/10.1109/VNC.2017.8275627>.

Історія статті:

Отримано: 21.04.2026 Доопрацьовано: 21.04.2026 Прийнято до друку: 23.05.2026 Опубліковано: 29.05.2026