

[DOI 10.28925/2663-4023.2025.28.815](https://doi.org/10.28925/2663-4023.2025.28.815)

УДК УДК 004.42:004.7:004.9

Коваленко Данило Сергійович

аспірант

Державний університет інформаційно-комунікаційних технологій, Київ, Україна

ORCID ID: 0009-0002-2475-2883

d.kovalenko@stud.duikt.edu.ua**Замрій Ірина Вікторівна**

доктор технічних наук, професор, завідувач кафедри Інженерії програмного забезпечення

Державний університет інформаційно-комунікаційних технологій, Київ Україна

ORCID ID: 0000-0001-5681-1871

i.zamrii@duikt.edu.ua

ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ АДАПТИВНОГО АЛГОРИТМУ МАРШРУТИЗАЦІЇ ДЛЯ C2C ЛОГІСТИКИ

Анотація. У статті представлено результати емпіричного дослідження інноваційного адаптивного алгоритму маршрутизації, розробленого для підвищення ефективності системи доставки в сегменті «клієнт-до-клієнта» (C2C). Такий підхід є особливо актуальним в умовах зростаючої популярності онлайн-маркетплейсів і мобільних платформ, де основною проблемою залишається так званий «останній кілометр» доставки — фінальний етап переміщення вантажу до кінцевого отримувача. Запропонований алгоритм базується на поєднанні довготривалої пам'яті (LSTM) для прогнозування попиту та методів підкріплювального навчання (Reinforcement Learning) для прийняття рішень у реальному часі. Експериментальні випробування проводились у середовищі середнього міста з типовою урбаністичною структурою. Для тестування використовувалися реальні дані про дорожню ситуацію, погодні умови та зміни в попиті на логістичні послуги. Результати продемонстрували значне зменшення логістичних витрат (до 18%) та часу доставки (на 15–20%) у порівнянні з традиційними алгоритмами (Дейкстра, A* тощо). Також підтверджено високу адаптивність алгоритму до змінних умов, що робить його придатним до інтеграції у динамічні C2C логістичні платформи. У статті також детально описано методологію дослідження, зокрема архітектуру тестового фреймворку, метрики оцінювання (витрати, час, точність) і процедури валідації результатів. Окрему увагу приділено порівнянню з існуючими підходами, а також виявленню обмежень та потенційних шляхів подальшого вдосконалення. Робота становить інтерес як для академічного середовища, так і для бізнесу, що орієнтований на створення гнучких, масштабованих систем доставки нового покоління.

Ключові слова: C2C логістика; адаптивна маршрутизація; останній кілометр; реальний час; оптимізація; машинне навчання; підкріплювальне навчання.

ВСТУП

Сегмент C2C логістики стрімко розвивається завдяки зростанню онлайн-маркетплейсів і мобільних платформ для обміну товарами. Ключовим викликом є проблема "останнього кілометра" — доставка між кінцевими споживачами без централізованих логістичних хабів. Як зазначено в [1], [2], ефективна маршрутизація в умовах динамічного попиту, змін трафіку та обмежених ресурсів є критично важливою для забезпечення сталості C2C-моделі. Традиційні методи, такі як алгоритм Дейкстри чи евристичні підходи, не здатні повною мірою адаптуватися до непередбачуваних змін, що призводить до затримок і підвищених витрат [3], [4].



Аналіз останніх досліджень і публікацій. На відміну від традиційної логістики В2С, де процес доставки централізований, моделі С2С характеризуються високою динамічністю, нерівномірним розподілом ресурсів та коливаннями попиту [5]. В результаті виникають проблеми маршрутизації, які неможливо ефективно вирішити за допомогою статичних методів, оскільки стан системи швидко змінюється. Дослідження показують, що класичні алгоритми пошуку найкоротшого шляху, такі як алгоритм Дейкстри або A^* , добре працюють у фіксованих дорожніх мережах, але не здатні ефективно адаптувати маршрути до змін у розподілі трафіку та попиту [6].

Одним із підходів до подолання цих обмежень є використання навчання з підкріпленням (RL), яке дозволяє агентам приймати рішення в режимі реального часу на основі історичних та поточних системних даних. RL застосовується до задач маршрутизації, де рішення необхідно адаптувати до змін умов навколишнього середовища, таких як затори, несприятлива погода або коливання попиту [7]. У роботі [8] було продемонстровано, що алгоритми на основі Q-навчання забезпечують більш оптимальні маршрути для динамічних логістичних систем порівняно з традиційними методами. Крім того, було виявлено, що глибокі нейронні мережі (Deep Q-Network, DQN) значно підвищують адаптивність моделей RL, але їхня ефективність залежить від якості даних та точності прогнозування майбутнього стану.

Критичним компонентом успішного застосування RL є здатність прогнозувати майбутнє навантаження системи. Використання глибоких нейронних мереж, таких як Long Short-Term Memory (LSTM), дозволяє враховувати часові залежності у вхідних даних, що дозволяє прогнозувати розміщення нових замовлень у різних місцях [9]. Методи прогнозування попиту на основі нейронних мереж, зокрема LSTM, дозволяють точно визначати часові залежності у попиті та прогнозувати зони навантаження [10], [11], [12]. Це знижує ймовірність затримок у доставці, проте інтеграція таких прогнозів у динамічну маршрутизацію залишається недостатньо вивченою.

Дослідження [13] показало, що поєднання прогнозування попиту з алгоритмами маршрутизації може значно підвищити ефективність логістичних систем, зменшуючи кількість «порожніх» рейсів та оптимізуючи робоче навантаження кур'єрів. Це особливо актуально для міських логістичних платформ, де розподіл попиту може швидко змінюватися.

Проблема обчислювальних витрат для масштабування алгоритмів на великі міські системи розглядається у роботах [10], [14], [15]. Проте інтеграція таких рішень у С2С логістику ще потребує доопрацювання.

Дослідження [16] присвячене розробці методології маршрутизації для логістики С2С через інтеграцію навчання з підкріпленням та прогнозування попиту. У ньому детально описано алгоритм для динамічного визначення маршрутів на основі змінних середовища. Його ефективність оцінювалася в середовищі моделювання, де він показав значне зменшення відхилення від оптимального маршруту, а також покращення часу доставки та використання транспортної мережі.

Постановка проблеми. Представлений у роботі [16] адаптивний алгоритм маршрутизації, який поєднує прогнозування попиту на основі нейронних мереж (LSTM) і підкріплювальне навчання (RL) для оптимізації маршрутів у реальному часі, потребує реальних випробувань для оцінки його продуктивності під час роботи з неповними або зашумленими вхідними даними, а також його здатності адаптуватися до динамічних транспортних умов.

Мета статті. Ця стаття присвячена експериментальному дослідженню розробленому в [16] алгоритму в реальних умовах, акцентуючи на фреймворку



тестування, методах оцінки ефективності та аналізі результатів. Метою є емпірична перевірка алгоритму, визначення його практичного потенціалу та порівняння з традиційними підходами.

ТЕОРЕТИЧНІ ОСНОВИ ДОСЛІДЖЕННЯ

Фреймворк тестування базується на реальному міському середовищі, що забезпечує високу достовірність результатів і їхню застосовність до практичних сценаріїв С2С логістики. Експерименти проводилися в умовах середнього міста з населенням приблизно 500 тисяч осіб, що відображає типову міську екосистему з розвиненою, але неоднорідною транспортною інфраструктурою. Вибір такого середовища обґрунтований його репрезентативністю, а саме, місто поєднує щільно забудовані центральні райони з високим попитом на доставку, спальні райони з піковими навантаженнями в певні години та віддалені околиці з низькою щільністю замовлень і довгими маршрутами. Це дозволяє оцінити адаптивність алгоритму до різних топографічних і логістичних умов.

Для забезпечення реалістичності експериментального середовища використано три ключові джерела даних:

1. *Дані про дорожній трафік.* Використовувався Google Maps API (зокрема компонент Historical Traffic), який надає інформацію про поточну дорожню ситуацію з оновленням кожні 5 хвилин. Цей інтервал оновлення дозволяє алгоритму оперативно реагувати на динамічні зміни, такі як затори, спричинені піковими годинами чи аваріями; ремонтні роботи, що обмежують доступ до певних ділянок. Пішохідні зони, які впливають на доступність для автомобілів і мотоциклів. API також враховує історичні патерни трафіку, що підвищує точність прогнозування затримок у реальному часі.

2. *Метеорологічні дані.* Через OpenWeather API отримувалися актуальні дані про погодні умови, включаючи опади (дощ, сніг), температуру, силу та напрямок вітру, а також видимість. Ці параметри критично впливають на продуктивність кур'єрів, особливо тих, що використовують велосипеди чи пішу доставку. Наприклад, дощ знижує швидкість велосипедистів на 15–20% через слизькі поверхні та знижену видимість; сильний вітер (понад 10 м/с) ускладнює пересування пішоходів і велосипедистів; низька температура може впливати на технічну надійність електромобілів чи акумуляторів мотоциклів.

3. *Дані про попит.* Аналітика попиту базувалася на реальних звітах платформ С2С-комерції, таких як OLX, Prom і Shafa [4], [17]. Ці платформи є лідерами в сегменті С2С в Україні, а їхні дані відображають реальні патерни поведінки користувачів. Аналітика дозволила змодельовати приблизно 100 логістичних вузлів (точок прийому/передачі замовлень) із різною щільністю замовлень; виділити пікові періоди активності: ранкові (8:00–10:00, доставка перед роботою) та вечірні (18:00–20:00, післяробочий час) та врахувати сезонні та ситуативні коливання попиту, наприклад, зростання замовлень під час акцій чи свят.

Використання реальних даних із зазначених джерел забезпечило високу валідність експериментів, дозволяючи оцінити алгоритм у середовищі, максимально наближеному до реальних умов експлуатації.



МЕТОДИКА ДОСЛІДЖЕННЯ

Для оцінки адаптивності та стабільності алгоритму розроблено набір сценаріїв тестування, поділених на два типи: статичні та динамічні. Кожен сценарій мав чітко визначені вхідні дані (кількість замовлень, типи транспорту, часові вікна, обмеження) та очікувані результати (оптимальний час доставки, мінімальні витрати, висока точність). Такий підхід дозволив оцінити алгоритм як у контрольованих, так і в непередбачуваних умовах.

Статичні сценарії моделювали стабільні умови без значних зовнішніх змін. Вони слугували базовою лінією для оцінки ефективності алгоритму в ідеалізованих умовах, що дозволяє порівняти його з традиційними методами маршрутизації (алгоритм Дейкстри, жадібний алгоритм). Основні характеристики статичних сценаріїв:

- фіксований попит - кількість замовлень залишалася сталою (наприклад, 50 замовлень на годину в центральних районах);
- стабільні умови - відсутність заторів, погодних змін чи несподіваних подій (перекриття доріг, відмови клієнтів);
- часові вікна - замовлення мали стандартні часові вікна (наприклад, 2 години, 10:00–12:00) і фіксовані пріоритети (звичайні замовлення);
- очікувані результати - оптимізація маршрутів із мінімальними витратами (еталон — 100 грн/замовлення [4]) і часом доставки (еталон — 45 хвилин [2]).

Статичні сценарії дозволили оцінити базову продуктивність алгоритму, його здатність генерувати оптимальні маршрути за відсутності зовнішніх перешкод і порівняти результати з теоретичними прогнозами з роботи [16].

Динамічні сценарії моделювали реальні виклики С2С логістики, пов'язані з непередбачуваними змінами. Вони тестували здатність алгоритму адаптуватися до раптових змін у попиті, трафіку, погоді чи поведінці клієнтів. Основні характеристики динамічних сценаріїв:

- піки попиту - раптове зростання замовлень на 40–60% (наприклад, під час акцій на платформах типу "Чорна п'ятниця"), що вимагало швидкого перерозподілу ресурсів;
- затори - збільшення часу доставки на 20–30% на окремих ділянках через дорожні пробки чи аварії, що моделювалося через Google Maps API;
- погодні впливи - дощ, який знижував швидкість велосипедистів на 15%, чи сильний вітер, що обмежував пішу доставку;
- перекриття доріг - ситуації, коли певні маршрути ставали недоступними через ремонт чи міські заходи;
- відмови клієнтів - сценарії, коли клієнт скасовував замовлення після початку доставки, що вимагало оперативного перепланування маршрутів;
- очікувані результати - збереження високої точності доставки (еталон — 85% [1]), мінімізація додаткових витрат і часу в умовах нестабільності.

Кожен динамічний сценарій включав набір вхідних даних (наприклад, 100 замовлень, 20% термінових, 30% у центральних районах) і чіткі КРІ для оцінки (витрати, час, точність). Це дозволило оцінити адаптивність алгоритму та його здатність до самонавчання в реальному часі.

Фреймворк тестування враховував гетерогенність агентів і ресурсів, що відображає реальну структуру С2С логістики, де кур'єри використовують різні типи транспорту з унікальними характеристиками. У тестуванні брали участь чотири типи кур'єрів, кожен із яких мав специфічні переваги та обмеження.

Таблиця 1

Характеристики та застосування кур'єрів у С2С логістиці

Тип кур'єра	Характеристики	Переваги	Обмеження	Типові замовлення
Пішоходи	Швидкість 5 км/год, до 5 кг, нульовий CO ₂	Екологічність, маневреність у центрі	Низька швидкість, мала місткість, непридатні для термінових	Малі посилки в радіусі 1–2 км
Велосипеди	Швидкість 15 км/год, до 10 кг, залежні від погоди	Екологічність, уникнення заторів, середня швидкість	Обмеження по погоді, дальність до 5–7 км	Середні посилки в межах району
Мотоцикли	Швидкість до 40 км/год, до 20 кг	Висока швидкість, маневреність, підходять для термінових	Витрати на паливо, менша екологічність	Термінова доставка на 10–15 км
Автомобілі	Швидкість до 50 км/год, до 100 кг	Велика місткість, доставка великих вантажів на відстані	Залежність від заторів, високі витрати, слабка маневреність	Великі або численні замовлення на околиці

Урахування гетерогенності агентів дозволило наблизити моделювання до реальних умов С2С логістики. Кожен тип кур'єра виявив свою ефективність у певних умовах: пішоходи – оптимальні для густонаселених центральних зон; велосипедисти – забезпечують баланс між швидкістю та екологічністю; мотоциклісти – незамінні при термінових доставках; автомобілі – ключові для великих чи багатоточкових доставок. Така структура дозволяє алгоритму гнучко розподіляти ресурси відповідно до специфіки замовлень, оптимізуючи витрати та час доставки. Основні етапи експериментального дослідження представлено на рис.1.




Рис. 1 Основні етапи експериментального дослідження



Даний фреймворк тестування був побудований з урахуванням різноманітних характеристик замовлень, що максимально наближало модель до реалій С2С логістики. Зокрема, кожне замовлення могло мати фіксований часовий інтервал доставки, наприклад, з 10:00 до 13:00. Це вимагало від алгоритму чіткого планування маршруту, щоб забезпечити вчасне прибуття. Крім того, замовлення відрізнялися за рівнем пріоритетності: близько 70% були звичайними, а решта 30% – терміновими, що мали суворі часові обмеження і потребували першочергового обслуговування. Також враховувалися додаткові умови, наприклад, доставка безпосередньо до під'їзду або на конкретний поверх, що впливало на загальний час обробки замовлення. Ця багатшарова структура дозволила оцінити ефективність алгоритму з урахуванням специфіки кожного типу кур'єра та складності самих замовлень.

Технічна реалізація фреймворку передбачала створення гнучкої та масштабованої інфраструктури, яка забезпечує високу точність і адаптивність. В її основі лежала платформа AnyLogic, що дозволяла здійснювати агентно-орієнтоване моделювання. Завдяки цьому можна було симулювати поведінку кур'єрів, клієнтів та всієї транспортної мережі, а також відстежувати зміни маршрутів у реальному часі й взаємодію між агентами, наприклад, у ситуаціях, коли кілька кур'єрів одночасно претендують на одну і ту ж вузьку вуличку.

Для обробки даних і реалізації складних алгоритмів машинного навчання використовувалася мова програмування Python. Один із ключових компонентів — нейронна мережа LSTM — застосовувався для прогнозування попиту на основі історичних даних С2С-платформ. Ця модель враховувала добові й сезонні коливання. Ще один елемент — алгоритм з підкріпленням (Q-learning) — відповідав за адаптацію маршрутів у реальному часі. Він працював за принципом нагород, тобто, чим кращий результат (наприклад, швидша доставка чи менші витрати), тим вища «винагорода», що дозволяло системі вчитися на власному досвіді. Окремі скрипти обробляли дані з Google Maps API та OpenWeather API, оновлюючи їх кожні п'ять хвилин. Це дало змогу враховувати актуальні умови трафіку, погоди, а також попит на послуги доставки.

Початкову оптимізацію маршрутів здійснювали за допомогою генетичних алгоритмів. Вони використовували функцію пристосованості, що поєднувала в собі економічну ефективність, час доставки та екологічність. Основними механізмами були схрещування (об'єднання двох маршрутів) і мутація (випадкова зміна маршруту) для пошуку найбільш вигідних рішень. Усі розрахунки здійснювалися на потужному сервері з 16-ядерним процесором Intel Xeon, 64 ГБ оперативної пам'яті та графічною картою NVIDIA Tesla V100. Це забезпечувало здатність обробляти до тисячі замовлень на годину та перебудовувати маршрути менш ніж за секунду.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Фреймворк виявився надзвичайно ефективним дослідницьким інструментом завдяки кільком важливим характеристикам. По-перше, він максимально наближений до реальності — включає дані про погоду, трафік і попит, що дозволяє екстраполювати результати на інші міста та платформи. По-друге, система дуже гнучка — вона підтримує як статичні, так і динамічні сценарії, охоплюючи широкий спектр умов від типових до екстремальних. По-третє, її гетерогенна структура, яка охоплює різні типи кур'єрів і замовлень, точно відображає складність реального середовища С2С логістики.



Крім того, фреймворк легко масштабований і може бути адаптований для вирішення задач у сфері B2C або B2B логістики. Важливо також, що він відповідає сучасним вимогам сталого розвитку, надаючи перевагу екологічно чистим видам транспорту. Однак, як і будь-яка складна система, він має обмеження. Зокрема, його ефективність сильно залежить від доступності точних даних із зовнішніх API, що може стати проблемою у менш розвинених регіонах. Також, для забезпечення належної продуктивності потрібно потужне обладнання, що ускладнює впровадження фреймворку малими компаніями. І нарешті, він не враховує людський фактор — наприклад, небажання кур'єра виконувати певні завдання, що може впливати на точність прогнозів.

Експериментальне моделювання логістичного фреймворку проводилося в умовах реального міського середовища середнього розміру, де проживає близько 500 тисяч осіб. Такий вибір був обґрунтованим — місто є типовим прикладом урбаністичного простору з поєднанням щільно забудованих центрів, спокійних спальних районів і віддалених околиць. Це створило різноманітні умови для тестування — від інтенсивного трафіку до низької щільності замовлень, що дозволило всебічно оцінити адаптивність і продуктивність алгоритму.

Умовно вся територія була поділена на три логістичні зони зі специфічними характеристиками:

1. У центральних районах спостерігалася найвища щільність замовлень — до 50 на квадратний кілометр. Тут розташовані офіси, магазини та висока концентрація людей. Однак саме ця зона виявилася найскладнішою для планування: вузькі вулиці, пішохідні зони, часті обмеження для автомобілів і регулярні затори в години пік. Такі умови вимагали залучення маневрених і мобільних кур'єрів, зокрема пішоходів або велосипедистів, які могли б ефективно обслуговувати невеликі замовлення в умовах обмеженої доступності.

2. Спальні райони мали середню щільність замовлень — 20–30 на квадратний кілометр — з найбільшою активністю у вечірній час, коли мешканці поверталися з роботи. Дорожня мережа тут була ширшою, але трафік залишався помірним. Утім, вечірні затори могли спричинити затримки доставки на 10–15%. Основним викликом у цій зоні було знайти оптимальний баланс між швидкістю обслуговування і вартістю доставки, адже маршрути мали середню довжину, а часові вікна — були більш гнучкими.

3. На окраїнах міста кількість замовлень була найнижчою — лише 5–10 на квадратний кілометр, через меншу щільність населення. Однак саме тут логістика вимагала особливої уваги, а саме, маршрути могли сягати до 15 км, а інфраструктура була недостатньо розвинена. Деякі ділянки не мали тротуарів або були важкодоступними. У таких умовах найдоцільнішим виявлялося використання автомобілів — єдиного типу транспорту, здатного ефективно долати довгі відстані і перевозити великогабаритні замовлення.

Для побудови достовірної моделі попиту було використано аналітичні звіти з найбільших українських платформ C2C-комерції, таких як OLX, Prom і Shafa. Ці ресурси надали інформацію для моделювання приблизно 100 логістичних вузлів — точок, де клієнти могли надсилати або отримувати посилки. Дані також дозволили ідентифікувати пікові години — ранкові періоди між 8:00 і 10:00 та вечірні між 18:00 і 20:00 — а також сезонні коливання, зокрема під час акцій, як-от Чорна п'ятниця.

Алгоритм працював із даними, які постійно оновлювалися в режимі реального часу. Через інтеграцію з Google Maps API враховувалися поточні затори, ремонти доріг або обмеження на окремих ділянках. OpenWeather API надавав інформацію про погодні



умови — дощ, вітер і температура, які безпосередньо впливали на швидкість і безпеку кур'єрів, особливо велосипедистів.

Щоб перевірити, наскільки система здатна адаптуватися до непередбачуваних змін, було змодельовано низку динамічних сценаріїв. Наприклад, під час пікового попиту кількість замовлень збільшувалася на 50%, що вимагало негайного перерозподілу ресурсів. В інших ситуаціях затори збільшували час доставки на 20–30% на окремих маршрутах, або погодні умови (наприклад, дощ) зменшували ефективність певного типу кур'єрів — наприклад, велосипедисти уповільнювалися на 15%. Додатково розглядалися ситуації з несподіваними обставинами — від перекриття вулиць до технічних несправностей, як-от поломка транспорту чи відмова клієнта отримати замовлення.

Технічна реалізація маршрутизуючого алгоритму, розробленого у межах дослідження, ґрунтується на концепції гібридної системи, що поєднує найсучасніші підходи з області оптимізації, машинного навчання та екологічного планування. Така архітектура дозволила створити адаптивне, гнучке й ефективне рішення для інтелектуальної логістики в умовах реального міського середовища.

Основу системи склали три ключові компоненти: генетичні алгоритми, підкріплювальне навчання та екологічна орієнтація. Кожен із цих елементів відіграв свою унікальну роль у побудові маршрутів та їхній подальшій оптимізації.

Перший етап — генерація початкових маршрутів — здійснювався за допомогою генетичних алгоритмів. Вони моделювали процес еволюції, поступово покращуючи рішення шляхом відбору найкращих варіантів. Оцінка ефективності кожного маршруту базувалася на так званій функції пристосованості, яка включала в себе три показники: економічні витрати (наприклад, паливо, амортизація, час роботи кур'єра), загальний час доставки та екологічність (перевага транспорту з низьким викидом CO₂).

Побудова нових маршрутів відбувалася через механізми схрещування (поєднання двох успішних маршрутів) і мутації (випадкові зміни, наприклад, зміна типу кур'єра чи порядку обслуговування клієнтів). Це дозволяло уникати так званих локальних оптимумів — ситуацій, коли алгоритм «застрягає» на посередньому рішенні. При цьому враховувалися реальні обмеження: допустима вага вантажу для певного кур'єра, часові вікна доставки та доступний тип транспорту.

Другий етап — адаптація в реальному часі — реалізовувався за допомогою підкріплювального навчання. У цьому контексті використовувався метод Q-learning, який діє як система прийняття рішень із винагородами. Алгоритм постійно аналізував поточну ситуацію: дорожній трафік, погодні умови, нові або скасовані замовлення. За кожне своє рішення він отримував оцінку — позитивну або негативну. Наприклад, якщо кур'єр доставив замовлення вчасно, це додавало «балів» у системі, а затримка — зменшувала їх.

Цей підхід дозволяв алгоритму самонавчатися: з кожною ітерацією він оновлював свою внутрішню стратегію та знаходив усе ефективніші маршрути. Якщо, скажімо, під час дощу велосипедисти починали запізнюватись, система могла швидко перерозподілити навантаження: термінові замовлення передати мотоциклістам, а пішоходам залишити короткі маршрути в центрі міста. Така здатність до адаптації значно перевершує можливості класичних логістичних алгоритмів, які не враховують змін середовища.

Третім важливим компонентом системи стала екологічна орієнтація. Алгоритм був розроблений із чітким фокусом на зменшення вуглецевого сліду. Це означає, що у випадках, коли це не впливало негативно на швидкість і витрати, перевага



надавалася так званим «зеленим» видам транспорту — пішоходам, велосипедам та електромобілям.

У щільній забудові центрів міста перевага надавалася пішим кур'єрам, які могли легко обходити затори та мали нульовий екологічний слід. У менш густонаселених районах, особливо на околицях, замовлення з великою вагою передавалися електромобілям, які забезпечували нижчі викиди в порівнянні з бензиновими авто.

Завдяки такому підходу алгоритм не лише оптимізував витрати й підвищував ефективність доставки, а й відповідав сучасним стандартам сталого розвитку та ESG-критеріям, що дедалі частіше стають вимогою для логістичних компаній та міських сервісів.

Результати експериментів, що були проведені для оцінки продуктивності адаптивного алгоритму маршрутизації, становлять критичну частину всього дослідження. Вони дозволили не лише кількісно оцінити ефективність запропонованого підходу в умовах C2C логістики, а й здійснити порівняльний аналіз з усталеними методами, такими як алгоритм Дейкстри та жадібний метод. Цей аналіз охоплює як стандартні умови, так і змінні, динамічні сценарії, що максимально наближають експерименти до реальних міських умов.

У таблиці 2 наведено узагальнені результати 100 тестів, проведених у реальному міському середовищі середнього масштабу.

Таблиця 2

Порівняння ефективності алгоритмів

Метод	Витрати (грн/замовлення)	Час доставки (хв)	Точність (%)	Перерахунки маршруту
Алгоритм Дейкстри	100	45	85	3
Жадібний метод	95	42	88	5
Адаптивний (GA+RL)	82	38	92	12

Адаптивний алгоритм зменшив середні витрати на доставку на 18% порівняно з алгоритмом Дейкстри та на 13% порівняно з жадібним методом. Таке зниження стало можливим завдяки гібридному підходу, тобто, початкове глобальне планування за допомогою генетичних алгоритмів уникнуло зайвих пробігів і дублювання маршрутів, а підкріплювальне навчання дозволило адаптувати маршрути в режимі реального часу з урахуванням нових даних (наприклад, погодних умов або трафіку).

Адаптивна система доставляла замовлення в середньому за 38 хвилин, що на 7 хвилин швидше, ніж Дейкстра, і на 4 хвилини швидше за жадібний підхід. З урахуванням реалій міської логістики, де навіть кількахвилинна затримка може призвести до невдоволення клієнта або скасування замовлення, це значне досягнення.

Показник точності — тобто частка замовлень, доставлених у межах зазначеного клієнтом часового вікна — у адаптивного алгоритму сягнув 92%, тоді як у Дейкстри — 85%, а у жадібного методу — 88%. Така перевага свідчить про здатність системи ефективно справлятися із часовими обмеженнями, особливо в умовах високої динамічності.

Графік на рис.2 підтверджує, що адаптивний алгоритм стабільно забезпечує найнижчий середній час доставки в усіх сценаріях. Він показує, що адаптивний алгоритм (38 хвилин у середньому) стабільно випереджає Дейкстру (45 хвилин) і жадібний метод



(42 хвилини) у всіх сценаріях, включаючи пікові навантаження (40 хвилин) і затори (42 хвилини).

Адаптивний алгоритм здійснював у середньому 12 перерахунків маршруту за одну сесію — значно більше, ніж інші підходи (3–5). Це вказує на його активну реакцію на зміну умов і високу гнучкість. Варто зазначити, що літературою визначено умовний поріг у 15 перерахунків, після чого подальші корекції мають мінімальний вплив на ефективність. Отже, система функціонувала в оптимальному діапазоні, забезпечуючи високу адаптивність без перевантаження інфраструктури.

Щоб оцінити адаптивність алгоритму до реальних викликів, було створено кілька тестових сценаріїв із високим ступенем варіативності (дані у таблиці 3).

Таблиця 3

Результати в динамічних умовах

Сценарій	Витрати (грн)	Час доставки (хв)	Точність (%)
Пік попиту (+50%)	85	40	90
Затори (+30% часу)	88	42	88
Дощ (–15% швидкості)	84	39	91
Перекриття доріг	87	41	89

Під час різкого збільшення кількості замовлень адаптивна система змогла зберегти високий рівень точності (90%) і помірні витрати, що підтверджує її здатність до ефективного масштабування та динамічного балансування навантаження між кур'єрами. Навіть зі збільшенням часу в дорозі на 30%, алгоритм зумів адаптуватися через динамічну маршрутизацію і об'їзні шляхи, зберігши точність доставки на рівні 88% — це демонструє здатність до адаптації без значної втрати продуктивності.

Погодні фактори, зокрема дощ, призвели до незначного зниження швидкості велосипедистів. Але алгоритм компенсував це перерозподілом замовлень на інші типи транспорту, що дозволило зберегти середній час доставки на рівні 39 хвилин.

У випадку несподіваних змін інфраструктури система швидко перебудовувала маршрути, демонструючи стабільну роботу без втрати якості сервісу.




Рис. 2. Порівняння часу доставки

Графік на рис. 3 демонструє економічну ефективність адаптивного алгоритму, який знижує витрати до 82 грн/замовлення при 12 перерахунках маршрутів. Це на 18% і 13% менше, ніж у алгоритму Дейкстри та жадібного методу відповідно. Стабілізація витрат після 15 перерахунків вказує на оптимальний баланс між адаптивністю та обчислювальною складністю, що узгоджується з літературними даними [18].




Рис. 3. Залежність витрат від кількості перерахунків

ВИСНОВКИ ТА ПЕРСПЕКТИВИ ПОДАЛЬШИХ ДОСЛІДЖЕНЬ

Результати експериментального дослідження дозволяють зробити кілька важливих висновків, що мають як теоретичне, так і прикладне значення для розвитку адаптивної логістики в умовах C2C-моделі доставки.

Ключова гіпотеза дослідження полягала в тому, що поєднання генетичних алгоритмів (для стратегічного планування) та підкріплювального навчання (для тактичної адаптації) дозволить створити ефективну та гнучку систему маршрутизації. Емпіричні дані підтвердили це припущення: алгоритм GA+RL значно перевершив традиційні методи (Дейкстра та жадібний) за всіма ключовими показниками — вартістю, часом доставки та точністю. Це дозволяє стверджувати, що гібридні системи мають вищий потенціал для роботи в реальному, динамічно змінюваному логістичному середовищі.

Особливої уваги заслуговує здатність алгоритму адаптуватися до змін: трафік, погодні умови, пік попиту, несподівані події (перекриття доріг, відмови клієнтів тощо). У класичних алгоритмах такі чинники або ігноруються, або враховуються лише частково. Адаптивний підхід дозволяє у режимі реального часу перерозподіляти ресурси, змінювати маршрути й типи транспорту, мінімізуючи негативні наслідки зовнішніх впливів. Це має вирішальне значення для міської логістики, де непередбачуваність є нормою, а не винятком.



Показник точності доставки в рамках зазначених часових вікон досяг 92%, що є високим результатом у порівнянні з іншими методами. З точки зору клієнтського досвіду, дотримання вказаного часу є критично важливим — це підвищує довіру до платформи, зменшує кількість конфліктів і скасувань. З урахуванням зростаючої конкуренції в секторі доставки, точність стає не лише логістичним, а й маркетинговим активом.

Важливими перевагами є економія ресурсів (до 18% зменшення витрат на замовлення), покращення клієнтського досвіду за рахунок зниження часу очікування, надійність і точність у динамічному середовищі, відповідність принципам сталого розвитку — завдяки екологічно орієнтованій маршрутизації.

Одним із викликів, які виявило дослідження, є високе обчислювальне навантаження, пов'язане з частими перерахунками маршрутів. Хоча 12 перерахунків не перевищують теоретичну межу ефективності, вони вимагають потужної обчислювальної інфраструктури — серверів із GPU або хмарних рішень. Це може бути критичним обмеженням для малого чи середнього бізнесу. Рішенням може стати впровадження більш легких моделей, оптимізація структури алгоритму або використання edge-комп'ютігу — обробки даних безпосередньо на пристроях кур'єрів.

Інтеграція екологічної орієнтації в алгоритм дозволила не лише зменшити вуглецевий слід, а й підвищити соціальну відповідальність логістичної платформи. Пріоритет надавався пішим кур'єрам, велосипедистам і електромобілям, що узгоджується з сучасними цілями сталого розвитку. У контексті зростаючих вимог до ESG (Environmental, Social, Governance) показників, такі характеристики можуть стати перевагою при залученні партнерів, інвесторів і клієнтів, орієнтованих на сталий розвиток.

Отримані результати не лише підтверджують ефективність запропонованого адаптивного алгоритму, а й розкривають глибші тенденції в логістиці майбутнього, тобто, перехід від статичних до гнучких систем, інтеграція штучного інтелекту, орієнтація на сталий розвиток та персоналізацію доставки. Ці результати мають фундаментальне значення як для наукової логістичної теорії, так і для практичних застосувань. Вони доводять, що гібридний підхід на основі генетичних алгоритмів і підкріплювального навчання забезпечує значно вищу ефективність у порівнянні з класичними методами. Розроблений фреймворк, із незначними вдосконаленнями, може бути адаптований до інших сегментів (B2B, B2C) та масштабований для великих міст або транснаціональних платформ.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Boysen, N., Briskorn, D., & Emde, S. (2021). Last-mile delivery concepts: A survey from an operational research perspective. *OR Spectrum*, 43(1), 1–58. <https://doi.org/10.1007/s00291-020-00607-4>.
2. Lin, J., Zhou, W., & Cai, L. (2022). A review of last-mile delivery optimization using machine learning and soft computing. *Transportation Research Part E: Logistics and Transportation Review*, 160, Article 102655. <https://doi.org/10.1016/j.tre.2022.102655>.
3. Ghiani, G., Guerriero, F., Laporte, G., & Musmanno, R. (2003). Real-time vehicle routing: Solution concepts, algorithms and parallel computing strategies. *European Journal of Operational Research*, 151(1), 1–11. [https://doi.org/10.1016/S0377-2217\(02\)00915-3](https://doi.org/10.1016/S0377-2217(02)00915-3).
4. Statista Research Department. (2024). C2C e-commerce market analysis in Eastern Europe. Retrieved May 20, 2025, from <https://www.statista.com/statistics>.
5. Yan Y., Chow A. H., Ho C. P., Kuo Y. H., Wu Q., Ying C. (2022). Reinforcement Learning for Logistics and Supply Chain Management: Methodologies, State of the Art, and Future Opportunities. *Transportation*



- Research Part E: Logistics and Transportation Review, 162, 102712. <https://doi.org/10.1016/j.tre.2022.102712>.
6. Liu H., Zhang J., Zhou Z., Dai Y., Qin L. (2024). A Deep Reinforcement Learning-Based Algorithm for Multi-Objective Agricultural Site Selection and Logistics Optimization Problem. *Applied Sciences*, 14(18), 8479. <https://doi.org/10.3390/app14188479>.
 7. Cai H., Xu P., Tang X., Lin G. (2024). Solving the Vehicle Routing Problem with Stochastic Travel Cost Using Deep Reinforcement Learning. *Electronics*, 13(16), 3242. <https://doi.org/10.3390/electronics13163242>.
 8. Akinola O. I. (2024). Adaptive location-based routing protocols for dynamic wireless sensor networks in urban cyber-physical systems. *Journal of Engineering Research and Reports*, 26(7), 424-443. <https://doi.org/10.9734/jerr/2024/v26i71220>.
 9. Gen M., Lin L., Yun Y., Inoue H. (2018). Recent advances in hybrid priority-based genetic algorithms for logistics and SCM network design. *Computers & Industrial Engineering*, 125, 394-412. <https://doi.org/10.1016/j.cie.2018.08.025>.
 10. Chai, H., Zhang, H. M., Ghosal, D., & Chuah, C. N. (2017). Dynamic traffic routing in a network with adaptive signal control. *Transportation Research Part C: Emerging Technologies*, 85, 64-85, <https://doi.org/10.1016/j.trc.2017.08.017>.
 11. James, J. Q., Wen Yu, and Jiatao Gu. (2019), Online vehicle routing with neural combinatorial optimization and deep reinforcement learning. *IEEE Transactions on Intelligent Transportation Systems*, 20(10), 3806-3817. <https://doi.org/10.1109/TITS.2019.2909109>.
 12. Shelke, O., Pathakota, P., Chauhan, A., Khadilkar, H., Meisheri, H., Ravindran, B. (2023). Multi-Agent Learning of Efficient Fulfilment and Routing Strategies in E-Commerce. *Artificial Intelligence*, <https://doi.org/10.48550/arXiv.2311.16171>
 13. Singh A., Wiktorsson M., Hauge J. B. (2021). Trends In Machine Learning To Solve Problems In Logistics. *Procedia CIRP*, 103, 67-72. <https://doi.org/10.1016/j.procir.2021.10.010>.
 14. Nimmagadda V. S. P. (2020). AI-Powered Predictive Analytics for Retail Supply Chain Risk Management: Advanced Techniques, Applications, and Real-World Case Studies. *Distributed Learning and Broad Applications in Scientific Research*, 6, 152-194, <https://dlabi.org/index.php/journal/article/view/110>.
 15. Huang L. (2024). Evolving E-commerce Logistics Planning-Integrating Embedded Technology and Ant Colony Algorithm for Enhanced Efficiency. *General Economics*. <https://doi.org/10.48550/arXiv.2402.15965>.
 16. Kovalenko, D. S., & Zamrii, I. V. (2025). Development of an adaptive routing algorithm for C2C logistics using reinforcement learning. *Telecommunications and Information Technologies*, (1), 31-49. <https://doi.org/10.31673/2412-4338.2025.017718>.
 17. OLX Ukraine. (2023). Analytical report 2023: Demand for delivery in the C2C segment. Retrieved May 20, 2025, from <https://www.olx.ua>.
 18. Phiboonbanakit, T., Horanont, T., Huynh, V.-N., & Supnithi, T. (2021). A hybrid reinforcement learning-based model for the vehicle routing problem in transportation logistics. *IEEE Access*, 9, 163325-163347. <https://doi.org/10.1109/ACCESS.2021.3131799>.

**Danylo S. Kovalenko**

PhD student

State University of Information and Communication Technologies, Kyiv, Ukraine

ORCID ID: 0009-0002-2475-2883

d.kovalenko@stud.duikt.edu.ua

Iryna V. Zamrii

Doctor of Technical Sciences, Professor,

Head of the Department of Software Engineering

State University of Information and Communication Technologies, Kyiv, Ukraine

ORCID ID: 0000-0001-5681-1871

i.zamrii@duikt.edu.ua

EXPERIMENTAL STUDY OF AN ADAPTIVE ROUTING ALGORITHM FOR C2C LOGISTICS

Abstract. The article presents the results of an empirical study of an innovative adaptive routing algorithm developed to enhance the efficiency of parcel delivery systems in the customer-to-customer (C2C) logistics segment. This approach addresses the critical “last-mile” delivery challenge — the final stage of transporting goods directly to end-users — which is increasingly relevant due to the rapid growth of online marketplaces and mobile trading platforms. The proposed algorithm combines Long Short-Term Memory (LSTM) networks for demand forecasting with Reinforcement Learning (RL) techniques for real-time decision-making. Experimental testing was conducted in a mid-sized city environment, representing a typical urban ecosystem with heterogeneous transportation infrastructure. Real-world data on traffic conditions, weather patterns, and delivery demand dynamics were used in the simulations. The results demonstrate a substantial reduction in logistics costs (up to 18%) and delivery times (by 15–20%) compared to traditional methods such as Dijkstra and A* algorithms. Furthermore, the algorithm showed a high level of adaptability to changing conditions, making it suitable for integration into dynamic C2C logistics platforms. The paper details the research methodology, including the structure of the testing framework, evaluation metrics (cost, time, accuracy), and result validation procedures. Particular attention is given to a comparative analysis with existing approaches, the identification of limitations, and prospects for further development. The study is relevant both to academic research and to businesses focused on developing flexible, scalable next-generation delivery systems.

Keywords: C2C logistics; adaptive routing; last-mile delivery; real-time; optimization; machine learning; reinforcement learning.

REFERENCES

1. Boysen, N., Briskorn, D., & Emde, S. (2021). Last-mile delivery concepts: A survey from an operational research perspective. *OR Spectrum*, 43(1), 1–58. <https://doi.org/10.1007/s00291-020-00607-4>.
2. Lin, J., Zhou, W., & Cai, L. (2022). A review of last-mile delivery optimization using machine learning and soft computing. *Transportation Research Part E: Logistics and Transportation Review*, 160, Article 102655. <https://doi.org/10.1016/j.tre.2022.102655>.
3. Ghiani, G., Guerriero, F., Laporte, G., & Musmanno, R. (2003). Real-time vehicle routing: Solution concepts, algorithms and parallel computing strategies. *European Journal of Operational Research*, 151(1), 1–11. [https://doi.org/10.1016/S0377-2217\(02\)00915-3](https://doi.org/10.1016/S0377-2217(02)00915-3).
4. Statista Research Department. (2024). C2C e-commerce market analysis in Eastern Europe. Retrieved May 20, 2025, from <https://www.statista.com/statistics>.
5. Yan Y., Chow A. H., Ho C. P., Kuo Y. H., Wu Q., Ying C. (2022). Reinforcement Learning for Logistics and Supply Chain Management: Methodologies, State of the Art, and Future Opportunities. *Transportation Research Part E: Logistics and Transportation Review*, 162, 102712. <https://doi.org/10.1016/j.tre.2022.102712>.



6. Liu H., Zhang J., Zhou Z., Dai Y., Qin L. (2024). A Deep Reinforcement Learning-Based Algorithm for Multi-Objective Agricultural Site Selection and Logistics Optimization Problem. *Applied Sciences*, 14(18), 8479. <https://doi.org/10.3390/app14188479>.
7. Cai H., Xu P., Tang X., Lin G. (2024). Solving the Vehicle Routing Problem with Stochastic Travel Cost Using Deep Reinforcement Learning. *Electronics*, 13(16), 3242. <https://doi.org/10.3390/electronics13163242>.
8. Akinola O. I. (2024). Adaptive location-based routing protocols for dynamic wireless sensor networks in urban cyber-physical systems. *Journal of Engineering Research and Reports*, 26(7), 424-443. <https://doi.org/10.9734/jerr/2024/v26i71220>.
9. Gen M., Lin L., Yun Y., Inoue H. (2018). Recent advances in hybrid priority-based genetic algorithms for logistics and SCM network design. *Computers & Industrial Engineering*, 125, 394-412. <https://doi.org/10.1016/j.cie.2018.08.025>.
10. Chai, H., Zhang, H. M., Ghosal, D., & Chuah, C. N. (2017). Dynamic traffic routing in a network with adaptive signal control. *Transportation Research Part C: Emerging Technologies*, 85, 64-85. <https://doi.org/10.1016/j.trc.2017.08.017>.
11. James, J. Q., Wen Yu, and Jiatao Gu. (2019), Online vehicle routing with neural combinatorial optimization and deep reinforcement learning. *IEEE Transactions on Intelligent Transportation Systems*, 20(10), 3806-3817. <https://doi.org/10.1109/TITS.2019.2909109>.
12. Shelke, O., Pathakota, P., Chauhan, A., Khadilkar, H., Meisheri, H., Ravindran, B. (2023). Multi-Agent Learning of Efficient Fulfilment and Routing Strategies in E-Commerce. *Artificial Intelligence*, <https://doi.org/10.48550/arXiv.2311.16171>
13. Singh A., Wiktorsson M., Hauge J. B. (2021). Trends In Machine Learning To Solve Problems In Logistics. *Procedia CIRP*, 103, 67-72. <https://doi.org/10.1016/j.procir.2021.10.010>.
14. Nimmagadda V. S. P. (2020). AI-Powered Predictive Analytics for Retail Supply Chain Risk Management: Advanced Techniques, Applications, and Real-World Case Studies. *Distributed Learning and Broad Applications in Scientific Research*, 6, 152-194, <https://dlabi.org/index.php/journal/article/view/110>.
15. Huang L. (2024). Evolving E-commerce Logistics Planning-Integrating Embedded Technology and Ant Colony Algorithm for Enhanced Efficiency. *General Economics*. <https://doi.org/10.48550/arXiv.2402.15965>.
16. Kovalenko, D. S., & Zamrii, I. V. (2025). Development of an adaptive routing algorithm for C2C logistics using reinforcement learning. *Telecommunications and Information Technologies*, (1), 31-49. <https://doi.org/10.31673/2412-4338.2025.017718>.
17. OLX Ukraine. (2023). Analytical report 2023: Demand for delivery in the C2C segment. Retrieved May 20, 2025, from <https://www.olx.ua>.
18. Phiboonbanakit, T., Horanont, T., Huynh, V.-N., & Supnithi, T. (2021). A hybrid reinforcement learning-based model for the vehicle routing problem in transportation logistics. *IEEE Access*, 9, 163325-163347. <https://doi.org/10.1109/ACCESS.2021.3131799>.

