



ОПТИМІЗАЦІЯ ПРОЦЕСУ МАРШРУТИЗАЦІЇ В РОЗПОДІЛЕНИХ МЕРЕЖАХ З ВИКОРИСАННЯМ МАШИННОГО НАВЧАННЯ

С. Заблоцький [ORCID: 0009-0008-2265-4546], В. Пограничний [ORCID: 0009-0003-3535-5880],
А. Тарасенко [ORCID: 0009-0008-6938-4571], Р. Колодій [SCOPUS ID: 56566611400]

Національний університет “Львівська політехніка”, вул. С. Бандери, 12, Львів, 79013, Україна

Відповідальний за рукопис: Сергій Заблоцький (e-mail: serhii.o.zablotskyi@lpnu.ua).

У статті запропоновано інноваційний підхід до оптимізації маршрутизації в розподілених мережах із використанням методів машинного навчання, зокрема підкріплювального навчання. Використання цього підходу дає змогу істотно підвищити ефективність керування потоками даних, оскільки алгоритм адаптивно визначає оптимальні шляхи передавання на основі поточного стану мережі. Це сприяє зменшенню затримок, покращенню використання пропускної здатності та підвищенню загальної продуктивності мережевої інфраструктури. Динамічне пристосування до змін у топології мережі, навантаженні трафіку та доступності вузлів дає змогу ефективно керувати передаванням даних навіть у високодинамічних умовах. Запропонований метод надає змогу мережі самостійно навчатися та оптимізувати маршрути, знижуючи вплив непередбачуваних збоїв і змін у трафіку. Результати експериментального моделювання демонструють істотні переваги розробленого алгоритму порівняно з традиційними методами маршрутизації. Порівняно з алгоритмом Дейкстри новий підхід забезпечує зменшення середнього часу затримки на 15 %. Також спостерігається покращене використання пропускної здатності мережі, що сприяє збалансованому розподілу навантаження між вузлами. Завдяки адаптивному алгоритму мережа стає стійкішою до аварійних ситуацій, швидше реагує на зміни та ефективніше використовує наявні ресурси. Практичне значення отриманих результатів полягає у можливості впровадження цього підходу в різних сферах, зокрема в Інтернеті речей та бездротових мережах. Застосування алгоритму в таких середовищах дасть змогу істотно покращити якість обслуговування, підвищити рівень автономності мережевих вузлів і забезпечити оптимальне керування трафіком навіть за умов обмежених ресурсів. Подальші дослідження будуть спрямовані на вдосконалення запропонованого підходу, зокрема на його масштабування для підтримки великих мереж. Також важливим напрямом розвитку стане інтеграція алгоритму з передовими методами кібербезпеки, що дасть змогу створити захищеніші та надійніші мережеві системи.

Ключові слова: маршрутизація, машинне навчання, оптимізація, розподілені мережі, адаптація, затримки.

УДК: 621:351

Вступ

Оптимізація маршрутів у розподілених мережах є ключовою проблемою, що визначає ефективність функціонування сучасних телекомунікаційних систем. З розвитком технологій Інтернету речей (IoT), бездротових сенсорних мереж (WSN) та хмарних обчислень обсяги переданих даних постійно зростають, що створює додаткове навантаження на мережі. Традиційні методи маршрутизації, такі як алгоритм Дейкстри чи Беллмана – Форда, мають певні обмеження в умовах динамічних змін топології мереж, великої кількості вузлів та високих вимог до енергозбереження. Ці обмеження унеможливають адаптацію маршрутів у реальному часі, що негативно впливає на продуктивність мережі загалом [1], [2].

Сучасні розподілені мережі, такі як Інтернет речей (IoT), бездротові сенсорні мережі (WSN) та системи передавання даних, стикаються з низкою викликів, які негативно впливають на їхню ефективність. Основними з цих викликів є забезпечення низької затримки передавання даних, оптимізація використання пропускну здатності, енергоефективність та масштабованість. За великих обсягів трафіку або динамічних змін у мережевій топології традиційні методи маршрутизації стають малоефективними через їхню статичність та нездатність адаптуватися до змін у реальному часі. Одним із найбільших викликів є забезпечення гнучкості в умовах динамічних змін мережевих параметрів.

Наприклад, у мережах IoT, де вузли можуть бути мобільними або мати обмежені енергетичні ресурси, передавання даних стає критично залежним від своєчасного оновлення маршрутів. Традиційні протоколи, такі як OSPF (Open Shortest Path First) та RIP (Routing Information Protocol), хоча й забезпечують базові потреби маршрутизації, не здатні ефективно працювати в умовах високої динамічності та непередбачуваності мережевих умов.

Крім того, виникає проблема оптимального використання пропускну здатності мережі. У разі перевантаження або зростання попиту на ресурси збільшуються затримки, що може призводити до втрати пакетів і зниження продуктивності. Для мереж, які обслуговують критичні додатки (наприклад, у сфері охорони здоров'я або транспорті), це може мати серйозні наслідки.

Іншим важливим аспектом є безпека маршрутизації. У розподілених мережах часто виникають атаки, пов'язані з маніпуляцією маршрутами або перенаправленням трафіку через небезпечні вузли. Це ставить під загрозу як цілісність переданих даних, так і функціонування мережі загалом.

Наукова література пропонує низку підходів для вирішення зазначених проблем. Зокрема, машинне навчання (Machine Learning, ML) визнано перспективним інструментом для аналізу великих обсягів мережевих даних, прогнозування поведінки трафіку та динамічного оновлення маршрутів. Однак більшість запропонованих методів зосереджені на окремих аспектах маршрутизації, не враховують потреби інтегрованого підходу до одночасної оптимізації затримок, пропускну здатності та енергоефективності.

Отже, постає проблема розроблення універсального підходу до маршрутизації в розподілених мережах, який би об'єднував адаптивність, ефективність і безпеку. Ця проблема особливо актуальна для великих мереж із високою динамікою змін, де традиційні методи вже не справляються із сучасними викликами.

Огляд сучасних досліджень підтверджує високий інтерес до використання машинного навчання для вирішення завдань маршрутизації. Зокрема, у роботі [3] показано, що алгоритми підкріплювального навчання (Reinforcement Learning, RL) дають змогу ефективно адаптувати маршрути до змін у топології мережі, мінімізуючи затримки передавання; у [4] дослідили використання підходів машинного навчання для управління мережевим трафіком, акцентуючи на необхідності оброблення великих обсягів даних у реальному часі; у [5] автори звернули увагу на можливості когнітивного управління мережами з використанням алгоритмів ML, що сприяє підвищенню ефективності розподілу ресурсів.

Автори статті [6] зосередилися на потенціалі використання інтелектуальних алгоритмів для підвищення продуктивності бездротових сенсорних мереж, зосередивши увагу на їх енергоефективності. У дослідженні [7] розглянуто інтеграцію глибоких нейронних мереж (Deep Neural Networks, DNNs) для прогнозування мережевого трафіку, що дає змогу динамічно коригувати маршрути на основі передбачених змін; у [8] проаналізовано методи маршрутизації, які забезпечують якість обслуговування (Quality of Service, QoS) для мультимедійних застосунків, що важливо для сучасних комунікаційних мереж.

У роботі [9] продемонстровано ефективність алгоритмів маршрутизації в динамічних мережах із використанням підходів навчання із підкріпленням. Дослідження [10] підкреслює необхідність розроблення стійких алгоритмів ML для маршрутизації у великих розподілених мережах, що враховують як мережеві, так і енергетичні обмеження.

Попри вагомий прогрес у цій галузі, залишаються актуальними питання упровадження цих підходів у масштабних розподілених системах. Сучасні дослідження вказують на необхідність розроблення універсальніших алгоритмів, здатних забезпечувати баланс між продуктивністю та енергоефективністю.

Мета цього дослідження – створення та впровадження нового підходу до маршрутизації на основі методів машинного навчання, що забезпечить адаптивність, енергоефективність та підвищення продуктивності мережі.

Завдання роботи полягають у детальному аналізі відомих методів, розробленні алгоритму на основі ML для маршрутизації в умовах динамічних змін та оцінюванні його ефективності порівняно з традиційними підходами.

2. Аналіз та постановка задачі

Маршрутизація у розподілених мережах є критичною складовою їх ефективного функціонування, оскільки саме правильне планування шляхів передавання інформації забезпечує оптимальне використання ресурсів та мінімізацію затримок.

Традиційні методи, зокрема алгоритм Дейкстри [1] та Беллмана – Форда [2], забезпечують розв’язання задачі маршрутизації на основі статичних топологій мережі. Однак вони мають істотні обмеження у випадках динамічних змін, таких як часті збої вузлів або зміна мережевого трафіку в реальному часі [3].

У дослідженнях [3] та [7] висвітлено перспективи використання методів машинного навчання (ML) для маршрутизації, які дають змогу системі адаптуватися до змінних умов, за допомогою постійного навчання на основі нових даних. Зокрема, доведено ефективність алгоритмів підкріплювального навчання (RL) у вирішенні проблем, пов’язаних із непередбачуваною динамікою трафіку. Ці алгоритми дали змогу зменшити середню затримку передавання даних у мережах до 20 % порівняно із традиційними підходами.

Інші дослідження, такі як робота [6], показали, що застосування інтелектуальних алгоритмів дозволяє створювати прогностичні моделі для мережевого трафіку, забезпечуючи оптимізацію маршрутів заздалегідь. Разом із тим, робота [7] висвітлила переваги інтеграції ML із кластеризацією для зменшення складності задач маршрутизації у великих мережах. Проте використання ML у масштабних розподілених мережах все ще стикається з викликами щодо забезпечення масштабованості, енергозбереження та захисту від атак [10].

Аналіз сучасних підходів свідчить про необхідність розроблення гібридних методів маршрутизації, які поєднували б гнучкість ML із перевіреними традиційними алгоритмами для збереження ефективності в умовах реальних обмежень. Наприклад, в роботі [5] запропоновано модель, яка використовує *Q-learning* у поєднанні з евристичними правилами для досягнення оптимального балансу між точністю та швидкістю виконання.

На основі аналізу можна сформулювати такі основні проблеми, які потрібно вирішити:

1. Необхідність забезпечення адаптивності маршрутизації у реальному часі.
2. Розроблення енергоефективних алгоритмів, що враховують обмежені ресурси вузлів.
3. Підвищення стійкості до атак, зокрема атак на маршрутизацію та передавання даних.
4. Масштабованість алгоритмів для їх використання у системах із тисячами вузлів.

Формулювання завдання цього дослідження ґрунтується на виявлених проблемах і спрямоване на розроблення нового алгоритму маршрутизації, який використовує машинне навчання для динамічної адаптації маршрутів у реальному часі. Основне завдання – досягти оптимального співвідношення між швидкістю маршрутизації, продуктивністю мережі та енергоефективністю, враховуючи сучасні вимоги до безпеки та стійкості до атак.

Традиційні методи маршрутизації забезпечують ефективне розв’язання задач пошуку найкоротшого шляху в мережах із фіксованою топологією та стабільним трафіком. Однак вони мають низку істотних обмежень, які ускладнюють їх використання у сучасних динамічних розподілених мережах.

Одним із найбільших викликів для цих методів є мобільні мережі, в яких місце розташування вузлів постійно змінюється, що призводить до динамічної зміни топології. У таких умовах алгоритми не здатні швидко адаптувати маршрути через необхідність повного перерахунку шляхів, що призводить до значних затримок у передаванні даних. Наприклад, у мобільних *ad hoc* мережах (Mobile Ad Hoc Network, MANET) втрати зв'язку через переміщення вузлів стають критичним фактором, який унеможливорює стабільну роботу.

Ще однією серйозною проблемою є перевантаження вузлів у мережах із високим навантаженням. Статична маршрутизація, характерна для традиційних методів, не враховує динамічні зміни в завантаженості вузлів, що призводить до утворення “вузьких місць” у мережі.

У результаті істотно зростають затримки, відбувається втрата пакетів, а продуктивність системи суттєво знижується. Цей недолік особливо помітний у мережах IoT, де велика кількість сенсорів передає дані через обмежену кількість центральних вузлів.

У мережах із обмеженими ресурсами, таких як бездротові сенсорні мережі (WSN), традиційні підходи також демонструють низьку ефективність. Алгоритми, орієнтовані на пошук найкоротшого шляху, ігнорують рівень енергоспоживання вузлів, що призводить до швидкого виснаження енерго-ресурсів окремих елементів мережі. Якщо ж маршрути прокладають через вузли з мінімальним залишком енергії, їх вихід з ладу може спричинити порушення цілісності всієї системи.

Додатковим обмеженням є нездатність цих алгоритмів адаптуватися до високої динаміки трафіку, що характерно для сучасних хмарних обчислювальних систем і потокових сервісів.

Зміни в мережевому трафіку призводять до нерівномірного розподілу навантаження та зростання затримок, оскільки традиційні методи не можуть забезпечити оперативне перенаправлення даних. Наприклад, у потокових відеосервісах неефективна маршрутизація може спричинити буферизацію та істотні втрати якості обслуговування.

Безпека також є слабким місцем традиційних підходів. Ці алгоритми не враховують можливих загроз, пов'язаних із атаками на маршрутизацію, такими як “чорна діра” або перенаправлення трафіку через ненадійні вузли. Це створює ризики втрати даних і порушення їхньої цілісності, що особливо критично для застосувань у сферах медицини чи фінансів.

Нарешті, питання масштабованості залишається серйозним викликом. У великих мережах із тисячами вузлів, таких як сучасні мережі 5G чи хмарні інфраструктури, складність обчислень алгоритмів Дейкстри та Беллмана – Форда зростає експоненційно, що робить їх непридатними для використання у реальному часі.

Отже, наведені обмеження демонструють неспроможність традиційних підходів до маршрутизації ефективно функціонувати в умовах сучасних мереж із високою динамікою змін. Це обґрунтовує необхідність розроблення інноваційних підходів, які забезпечать адаптивність, енергоефективність і безпеку, зокрема за допомогою інтеграції методів машинного навчання.

3. Упровадження алгоритму пошуку шляху за критерієм мінімального часу проходження

Розподілені мережі – складна система, де кожен вузол відіграє критичну роль у забезпеченні ефективного обміну даними. Маршрутизація як ключовий елемент визначає, як пакети інформації пересуваються між вузлами. Машинне навчання пропонує інноваційні підходи для вирішення цієї проблеми завдяки здатності алгоритмів ML навчатися на основі даних, враховувати динамічні зміни та прогнозувати оптимальні маршрути.

Сучасні підходи до маршрутизації передбачають використання методів підкріплювального навчання, глибоких нейронних мереж та алгоритмів навчання з учителем. Наприклад, RL дає маршрутизатору змогу адаптуватися до динамічних умов мережі, використовуючи політики дій, які оновлюються на основі винагороди.

$$Q(s, a) \leftarrow Q(s, a) + \alpha [r + \gamma \max_{a'} Q(s', a') - Q(s, a)], \quad (1)$$

де $Q(s, a)$ – функція цінності дії a в стані s ; α – коефіцієнт навчання; r – винагорода, отримана після виконання дії a ; γ – фактор дисконтування; $\max_a Q(s', a')$ – максимальна функція цінності для наступного стану s' і усіх можливих дій a' .

Глибокі нейронні мережі використовують для прогнозування трафіку в реальному часі, що дає змогу мінімізувати час передавання даних. Наприклад, прогнозування потоку даних можна подати у вигляді:

$$y_t = \sigma(W_h h_{t-1} + W_x x_t + b), \quad (2)$$

де y_t – вихідний сигнал на поточному кроці часу t ; σ – активаційна функція; W_h – ваги для прихованого стану на попередньому кроці h_{t-1} ; W_x – ваги для вхідних даних x_t ; h_{t-1} – прихований стан на попередньому кроці часу; x_t – вхідні дані на поточному кроці часу; b – зміщення.

Для розроблення алгоритму пошуку шляху за критерієм мінімального часу проходження вибрано підхід підкріплювального навчання. Основна ідея полягає в тому, щоб навчити агента (маршрутизатор) вибирати маршрути, які мінімізують затримки передавання даних та враховують змінні мережеві умови.

Алгоритм має три основні етапи:

1. Ініціалізація станів мережі на основі топології та поточного трафіку.
2. Визначення функції винагороди, яка враховує затримку передавання (d) та використання пропускної здатності (b):

$$R = -(w_1 \cdot d + w_2 \cdot b), \quad (3)$$

де R – значення винагороди, є від'ємним, оскільки агент повинен мінімізувати як затримку (ddd), так і використання пропускної здатності b ; w_1, w_2 – вагові коефіцієнти, які визначають відносну важливість кожного з параметрів; (ddd) – затримка передавання даних. Це час, необхідний для передавання даних від відправника до одержувача; b – використання пропускної здатності каналу. Це кількість мережевих ресурсів, споживаних під час передавання даних.

Формула спрямована на створення балансу між двома ключовими показниками ефективності мережі:

1. Зменшення затримки передавання: агент вибирає маршрути, які забезпечують найшвидше передавання даних.
2. Оптимізація використання ресурсів мережі: маршрути вибирають так, щоб уникати перевантаження мережі.

Роль вагових коефіцієнтів: w_1, w_2 дають змогу адаптувати алгоритм до конкретних потреб мережі. Для реального часу (наприклад, відеодзвінків) важливіше зменшення затримки, тому w_1 може бути значно більшим за w_2 .

Для мереж із обмеженими ресурсами ваговий коефіцієнт w_2 буде пріоритетним, оскільки важливо ефективно використовувати пропускну здатність.

Формула дає змогу гнучко керувати маршрутизацією, спрямовуючи агента на досягнення оптимального балансу між мінімізацією затримок і раціональним використанням мережевих ресурсів. Налаштування вагових коефіцієнтів w_1 та w_2 забезпечує адаптацію алгоритму до специфічних умов або вимог мережі.

3. Навчання агента на основі моделі Q -learning із використанням нейронної мережі для апроксимації функції цінності.

На рис. 1 подано схему алгоритму пошуку шляху за критерієм мінімального часу проходження у розподілених мережах, який ґрунтується на методах машинного навчання. Алгоритм містить такі етапи:

Ініціалізація: Початок роботи з ініціалізацією початкових даних про стан мережі.

Перевірка стану: Визначення, чи існує поточний стан мережі. Якщо ні – повернення до початку для повторної ініціалізації.

Аналіз стану: Опрацювання даних про поточний стан мережі для визначення можливих рішень.

Оцінка можливих дій: Визначення, які маршрути є найоптимальнішими на основі заданих критеріїв.

Перевірка оптимальності: Якщо оптимальний маршрут знайдено, вибір маршруту завершує алгоритм. Якщо ні, здійснюється навчання агента для подальшого уточнення.

Навчання агента: Використання підходів підкріплювального навчання для удосконалення вибору маршруту.




Рис. 1. Алгоритм пошуку шляху за критерієм мінімального часу проходження у розподілених мережах

Ця схема відображає цикл постійного вдосконалення маршрутизації для мінімізації часу проходження даних у мережі.

Запропонований алгоритм пошуку шляху за критерієм мінімального часу проходження демонструє ефективність підходів машинного навчання для розв'язання задач маршрутизації у розподілених мережах. Застосування методів підкріплювального навчання дає змогу агентів адаптуватися до динамічних умов, що забезпечує підвищення продуктивності мережі та зменшення затримок. У результаті запропонована методологія може знайти практичне застосування в сучасних інформаційних системах, в яких необхідна висока швидкість опрацювання та передавання даних.

Для оцінювання ефективності алгоритму виконано серію експериментів на змодельованій мережі з 50 маршрутизаторами на операційній системі OpenWRT, які формують гібридну топологію мережі (рис. 2) [11].




Рис. 2. Топологія мережі




Рис. 3. Візуалізація подання сегмента топології мереж

На рис. 3 детально відображено один із сегментів мережі. Для моделювання обмежених ресурсів вузла було прийнято рішення встановити вагові метрики маршрутів, що дає змогу точніше оцінювати пропускну здатність і доступні ресурси кожного маршруту. Це забезпечує динамічне коригування пріоритетності маршрутів залежно від навантаження на вузли мережі та їхніх поточних можливостей, сприяючи оптимізації розподілу трафіку і підвищенню загальної ефективності мережі.

Основними параметрами моделювання були час затримки, пропускну здатність та рівень використання ресурсів.

Результати показали, що використання алгоритму підкріплювального навчання зменшує середній час передавання даних на 15 % порівняно із традиційним алгоритмом Дейкстри. Візуалізацію результатів наведено в табл. 1 та на рис. 4.

Таблиця 1

Порівняння ефективності алгоритмів маршрутизації

Алгоритм	Середній час затримки, мс	Пропускна здатність, %	Використання ресурсів, %
Дейкстри	35,2	85	90
Q-learning	29,8	92	88

На графіку (рис. 4) відображено порівняння середнього часу затримки передавання даних для двох алгоритмів маршрутизації: традиційного алгоритму Дейкстри та алгоритму на основі підкріплювального навчання (*Q-learning*). Як видно з результатів, алгоритм *Q-learning* демонструє значно нижчий час затримки (29,8 мс проти 35,2 мс), що підтверджує його перевагу у динамічних умовах розподіленої мережі.

Експериментальні результати показали, що алгоритм підкріплювального навчання (*Q-learning*) істотно перевершує традиційний алгоритм Дейкстри за показником середнього часу затримки. Зокрема, використання *Q-learning* дає змогу зменшити час передавання даних на 15 %, що підтверджує його ефективність у динамічних умовах розподілених мереж.

Крім того, *Q-learning* демонструє більшу пропускну здатність (92 % проти 85 %) та трохи нижчий рівень використання ресурсів (88 % проти 90 %), що підкреслює його адаптивність та оптимізацію роботи в умовах високого навантаження.

Після аналізу результатів, відображених на графіку (рис. 4), доцільно розглянути приклади практичного застосування запропонованого алгоритму в різних мережевих умовах і технологіях. Це дасть змогу підкреслити універсальність і практичну значущість отриманих результатів.




Рис. 4. Графік порівняння середнього часу затримки для алгоритмів Дейкстри та *Q-learning*

Запропонований алгоритм можна успішно впровадити у сфері Інтернету речей (IoT), де основними викликами є масштабованість і ефективність маршрутизації за обмежених ресурсів вузлів. У типових IoT-мережах, таких як розумні будинки або промислові системи, кожен вузол виконує завдання збирання, оброблення та передавання даних.

Використання алгоритму *Q-learning* дає змогу мінімізувати затримки передавання даних навіть за умов динамічної зміни топології мережі, наприклад, через переміщення мобільних вузлів. Завдяки адаптивній природі алгоритму маршрути оновлюються у режимі реального часу, що забезпечує ефективну координацію роботи розумних пристроїв. У результаті такі системи можуть функціонувати з мінімальними втратами енергії та підвищеною стійкістю до збоїв.

Перспективним напрямом використання запропонованого алгоритму є високонавантажені мережі, такі як центри обробки даних (ЦОД). Основним завданням таких систем є оптимальний розподіл мережевого трафіку між серверами для забезпечення високої продуктивності та мінімізації затримок. Алгоритм *Q-learning* може бути інтегрований у системи управління трафіком ЦОД, що дасть змогу адаптивно перенаправляти потоки даних у випадках перевантаження окремих серверів або каналів зв'язку. Це не лише підвищує загальну ефективність роботи центрів обробки даних, але й сприяє раціональнішому використанню ресурсів.

Мобільні мережі п'ятого покоління (5G) також є перспективним середовищем для застосування запропонованого алгоритму. 5G-мережі характеризуються високою щільністю пристроїв, різноманітністю сервісів та динамічними умовами роботи. Використання *Q-learning* дає змогу оперативно оновлювати маршрути передавання даних, враховуючи зміну параметрів мережі, таких як рівень завантаженості базових станцій або швидкість пересування користувачів. Це забезпечує стабільну якість зв'язку навіть у випадках різких змін у середовищі передавання даних. Наприклад, в умовах масових заходів, коли трафік є надзвичайно щільним, запропонований алгоритм дає змогу оптимально розподілити навантаження між базовими станціями, уникаючи перевантажень та забезпечуючи високу якість обслуговування для всіх користувачів.

Отже, спектр практичного застосування в різних сферах результатів дослідження широкий. Інтеграція алгоритму *Q-learning* у сучасні системи управління трафіком сприятиме підвищенню ефективності роботи мереж, їхньої стійкості до змін і оптимізації використання ресурсів. Подальші дослідження можна зосередити на розробленні гібридних підходів, які об'єднують переваги *Q-learning* із традиційними методами маршрутизації, що дасть змогу ще більше розширити потенціал практичного застосування.

Отримані результати підтверджують ефективність використання машинного навчання для оптимізації маршрутизації. Запропонований алгоритм демонструє істотні переваги у зменшенні затримок передавання даних та підвищенні ефективності використання пропускної здатності.

Проте виявлено певні обмеження, такі як необхідність значних обчислювальних ресурсів для навчання моделі та складність масштабування алгоритму на дуже великі мережі.

Перспективи подальшого розвитку полягають у створенні гібридних підходів, що поєднують традиційні методи з моделями машинного навчання, а також в інтеграції алгоритму з методами захисту від атак на маршрутизацію.

Результати, отримані в межах цього дослідження, відкривають широкі можливості для подальшого вдосконалення запропонованого алгоритму та його адаптації до складніших умов сучасних мереж. Одним із ключових напрямів розвитку є інтеграція інших методів машинного навчання для підвищення точності прийняття рішень. Наприклад, використання глибоких нейронних мереж (DNNs) для моделювання складних залежностей у трафіку дасть змогу підвищити ефективність прогнозування та адаптації маршрутизації в умовах високої динаміки.

Застосування методів навчання з учителем (Supervised Learning) може забезпечити точніше налаштування моделі для специфічних сценаріїв, наприклад, у мережах із заздалегідь відомими параметрами трафіку. Використання технік кластеризації (Unsupervised Learning) дасть змогу групувати вузли за рівнем навантаження або затримки, що сприятиме оптимальному розподілу

ресурсів у розподілених мережах. Такі підходи доповняють адаптивні можливості алгоритму *Q-learning*, зменшуючи залежність від лише підкріплювального навчання.

Ще одним перспективним напрямом є розроблення гібридних моделей, які об'єднують переваги *Q-learning* із традиційними алгоритмами маршрутизації. Поєднання гнучкості та адаптивності *Q-learning* із передбачуваністю та ефективністю класичних методів, таких як алгоритм Дейкстри, дасть змогу створити універсальний підхід, здатний працювати як у стабільних, так і в динамічних умовах. Наприклад, у мережах із фіксованою топологією базові маршрути можуть бути побудовані за допомогою алгоритму Дейкстри, тоді як *Q-learning* забезпечуватиме їх адаптацію в реальному часі у разі зміни умов. Такий підхід зменшить обчислювальне навантаження на систему, що є критичним для великих мереж.

Крім того, інтеграція методів еволюційного навчання, таких як генетичні алгоритми, може сприяти оптимізації пошуку найкращих маршрутів. Генетичні алгоритми можуть використовуватися для початкової оптимізації параметрів навчання, таких як коефіцієнти винагороди або фактор дисконтування, що забезпечить швидшу збіжність алгоритму *Q-learning*.

Подальші дослідження можуть також зосередитися на адаптації алгоритму до специфічних мережових середовищ. Наприклад, у бездротових сенсорних мережах (WSN) необхідно враховувати обмеження енергоспоживання вузлів, тоді як у мобільних мережах важливим стає урахування швидкості переміщення вузлів. Введення таких специфічних особливостей у модель маршрутизації дасть змогу істотно розширити її практичну застосовність.

З огляду на швидкий розвиток хмарних технологій і мереж 5G, перспективним є використання розподілених навчальних моделей, таких як федеративне навчання. Це дозволить навчати алгоритм на великих наборах даних без необхідності їх централізації, що підвищить безпеку і конфіденційність інформації. Своєю чергою, це сприятиме ефективному впровадженню алгоритму в системи, які обробляють критично важливі дані, наприклад, у медичних або фінансових мережах.

Отже, розвиток запропонованого алгоритму може охоплювати як технічне вдосконалення самого процесу навчання, так і його адаптацію до нових технологічних викликів. Поєднання методів машинного навчання із традиційними підходами відкриває перспективи створення ефективніших, стійкіших і масштабованіших рішень для сучасних розподілених мереж.

Висновки

У межах цього дослідження запропоновано алгоритм пошуку шляху за критерієм мінімального часу проходження, що ґрунтується на методах машинного навчання. Під час аналізування сучасних підходів до оптимізації маршрутизації в розподілених мережах виявлено низку істотних обмежень традиційних методів, таких як алгоритми Дейкстри чи Беллмана – Форда.

Основним недоліком цих алгоритмів є їх статичність, що не дає їм змогу ефективно адаптуватися до динамічних змін у топології мережі та трафіку. Запропонований підхід, оснований на підкріплювальному навчанні (Reinforcement Learning), продемонстрував здатність до адаптивності та ефективного прийняття рішень у реальному часі, що допомогло подолати зазначені обмеження.

Практичне значення отриманих результатів полягає у можливості застосування розробленого алгоритму в різних сучасних мережових середовищах, які характеризуються динамічністю змін і високими вимогами до продуктивності. Зокрема, запропонований підхід успішно вирішує завдання мінімізації середнього часу затримки передавання даних, що підтверджено експериментальними результатами: затримка зменшилася на 15 % порівняно із традиційними методами маршрутизації. Крім того, запропонований алгоритм дає змогу забезпечити ефективніше використання мережових ресурсів завдяки зниженню навантаження на вузли мережі.

Це особливо актуально для таких сфер, як Інтернет речей (IoT), де потрібна висока точність і швидкість маршрутизації в умовах обмежених ресурсів вузлів, бездротові сенсорні мережі (WSN), які характеризуються обмеженнями енергоспоживання, та мобільні мережі, що потребують швидкої адаптації до змін у топології.

Подальший розвиток запропонованого підходу має значний потенціал для вдосконалення. Одним із ключових напрямів є адаптація алгоритму для забезпечення масштабованості в умовах великих мереж із тисячами вузлів. Це передбачає оптимізацію обчислювальної складності алгоритму та його адаптацію до роботи в мережах із високою щільністю трафіку. Інтеграція алгоритму з методами захисту від атак на маршрутизацію – ще один перспективний напрям, який дасть змогу підвищити стійкість мереж до загроз, пов'язаних із маніпуляціями топологією чи несанкціонованим доступом до даних.

Важливим кроком у вдосконаленні алгоритму є розроблення енергоефективних моделей навчання, які враховуватимуть обмежені обчислювальні ресурси окремих вузлів у мережі. Це дасть змогу істотно розширити застосування алгоритму в мережах IoT та інших системах із жорсткими вимогами до споживання енергії. Додатковим напрямом є адаптація алгоритму для використання у хмарних і гібридних обчислювальних середовищах. Такий підхід забезпечить ефективне використання як локальних, так і глобальних мережеских ресурсів, що відкриває нові перспективи для застосування запропонованого рішення у хмарних інфраструктурах і системах розподілених обчислень.

Отже, результати цього дослідження сприяють розвитку технологій маршрутизації, забезпечуючи ефективність і адаптивність сучасних розподілених мереж. Запропонований підхід демонструє значний потенціал для вирішення завдань, пов'язаних із динамічними змінами умов роботи мереж, та може слугувати основою для розроблення нових методів оптимізації маршрутизації, здатних відповідати викликам сучасного цифрового світу.

Список використаних літературних джерел

- [1] José Craveirinha, João Clímaco, R. Girão-Silva, and M. Pascoal, "Multiobjective Path Problems and Algorithms in Telecommunication Network Design – Overview and Trends", *Algorithms*, vol. 17, No. 6, pp. 222–222, May 2024. Доступно за посиланням: <https://doi.org/10.3390/a1706022> (Accessed: 24 January 2025).
- [2] P. R. Tammanashastri, S. M. Rajagopal, and S. S. Bananjee, "Comparative Analysis of Bellman-Ford and Dijkstra Algorithms in Software Defined Networking", *2024 5th International Conference on Data Intelligence and Cognitive Informatics (ICDICI)*, pp. 1–8, Nov. 2024. Доступно за посиланням: <https://doi.org/10.1109/icdici62993.2024.10810921> (Accessed: 24 January 2025).
- [3] M. U. Younus, M. K. Khan, and A. R. Bhatti, "Improving the software defined wireless sensor networks routing performance using reinforcement learning," *IEEE Internet of Things Journal*, pp. 1–1, 2021. Доступно за посиланням: <https://doi.org/10.1109/jiot.2021.3102130> (Accessed: 24 January 2025).
- [4] D. Adesina, C.-C. Hsieh, Y. E. Sagduyu, and L. Qian, "Adversarial Machine Learning in Wireless Communications Using RF Data: A Review," *IEEE Communications Surveys & Tutorials*, vol. 25, No. 1, pp. 77–100, 2023. Доступно за посиланням: <https://doi.org/10.1109/COMST.2022.3205184> (Accessed: 24 January 2025).
- [5] F. Alhaidari et al., "Intelligent Software-Defined Network for Cognitive Routing Optimization using Deep Extreme Learning Machine Approach," *Computers, Materials & Continua*, vol. 67, No. 1, pp. 1269–1285, 2021. Доступно за посиланням: <https://doi.org/10.32604/cmc.2021.013303> (Accessed: 24 January 2025).
- [6] H. Sharma, A. Haque, and F. Blaabjerg, "Machine Learning in Wireless Sensor Networks for Smart Cities: A Survey," *Electronics*, vol. 10, No. 9, p. 1012, Apr. 2021. Доступно за посиланням: <https://doi.org/10.3390/electronics10091012> (Accessed: 24 January 2025).
- [7] M. A. Ridwan, N. A. M. Radzi, F. Abdullah, and Y. E. Jalil, "Applications of Machine Learning in Networking: A Survey of Current Issues and Future Challenges," *IEEE Access*, pp. 1–1, 2021. Доступно за посиланням: <https://doi.org/10.1109/access.2021.3069210> (Accessed: 24 January 2025).
- [8] R. Chiwariro, "Quality of service aware routing protocols in wireless multimedia sensor networks: survey," *International Journal of Information Technology*, Jul. 2020. Доступно за посиланням: <https://doi.org/10.1007/s41870-020-00478-w> (Accessed: 24 January 2025).
- [9] X. Qiu, L. Xu, P. Wang, Y. Yang, and Z. Liao, "A Data-Driven Packet Routing Algorithm for an Unmanned Aerial Vehicle Swarm: A Multi-Agent Reinforcement Learning Approach", *IEEE Wireless Communications Letters*, vol. 11, No. 10, pp. 2160–2164, Aug. 2022. Доступно за посиланням: <https://doi.org/10.1109/lwc.2022.3195963> (Accessed: 24 January 2025).

- [10] S. Hu, X. Chen, W. Ni, E. Hossain, and X. Wang, "Distributed Machine Learning for Wireless Communication Networks: Techniques, Architectures, and Applications", *IEEE Communications Surveys & Tutorials*, vol. 23, No. 3, pp. 1458–1493, 2021. Доступно за посиланням: <https://doi.org/10.1109/comst.2021.3086014> (Accessed: 24 January 2025).
- [11] Mukul Goyal, Mohd Soperi, Emmanuel Baccelli, Gagan Choudhury, Aman Shaikh, et al. *Improving Convergence Speed and Scalability in OSPF: A Survey*. *Communications Surveys and Tutorials, IEEE Communications Society*, 2012, 14 (2), pp. 443–463 (10.1109/SURV.2011.011411.00065).

OPTIMIZATION OF THE ROUTING PROCESS IN DISTRIBUTED NETWORKS USING MACHINE LEARNING

S. Zablotskyi, V. Pohranychnyi, A. Tarasenko, R. Kolodiy

Lviv Polytechnic National University, 12, S. Bandery str., Lviv, 79013, Ukraine

The article proposes an innovative approach to optimize the routing process in distributed networks using machine learning techniques, specifically reinforcement learning. This method enables the adaptive determination of optimal data transmission paths based on current network conditions, enhancing overall performance and resilience to dynamic traffic fluctuations. The proposed approach dynamically adjusts to variations in network topology, traffic load, and node availability, ensuring efficient data flow management even in highly dynamic environments. Experimental results demonstrate substantial benefits of the proposed algorithm over conventional routing methods. Compared to Dijkstra's algorithm, the new approach achieves a 15% reduction in average delay time, and improved utilization of network bandwidth. The practical significance of the obtained results lies in the potential deployment of the developed approach across various fields, including the Internet of Things, wireless sensor networks. This method can significantly enhance the performance of autonomous systems, intelligent transportation networks, and other critical infrastructures where reliability and speed are essential. Future research will focus on further refining the proposed approach, scaling it to support large-scale networks with thousands of nodes, integrating it with state-of-the-art cybersecurity measures, and developing energy-efficient learning models tailored for nodes with constrained computational resources. The proposed solution holds significant potential for improving the efficiency of modern network systems, paving the way for more intelligent and adaptive distributed network management.

Keywords: *routing, machine learning, optimization, distributed networks, dynamic adaptation, latency.*