



ОПТИМІЗАЦІЯ ПРОЦЕСУ МАРШРУТИЗАЦІЇ В РОЗПОДІЛЕНИХ МЕРЕЖАХ З ВИКОРИСТАННЯМ 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, 79013, Львів, 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 дозволяє значно підвищити ефективність керування потоками даних, оскільки алгоритм адаптивно визначає оптимальні шляхи передачі на основі поточного стану мережі. Це сприяє зменшенню затримок, покращенню використання пропускну здатності та підвищенню загальної продуктивності мережевої інфраструктури. Динамічне пристосування до змін у топології мережі, навантаженні трафіку та доступності вузлів дозволяє ефективно керувати передачею 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 суттєві переваги розробленого алгоритму в порівнянні з традиційними методами маршрутизації. У порівнянні з алгоритмом Дейкстри новий підхід забезпечує зменшення середнього часу затримки на 15%. Також спостерігається покращене використання пропускну здатності мережі, що сприяє збалансованому розподілу навантаження між вузлами. Завдяки адаптивному характеру алгоритму мережа стає стійкішою до аварійних ситуацій, швидше реагує на зміни та ефективніше використовує наявні ресурси. Практичне значення отриманих результатів полягає в можливості впровадження цього підходу в різних сферах, зокрема в Інтернет речей та бездротових мережах. Застосування алгоритму в таких середовищах дозволить значно 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 напрямком розвитку стане інтеграція алгоритму з передовими методами кібербезпеки, що дозволить створити захищеніші та більш надійні 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 в цілому [1], [2].

Сучасні розподілені мережі, такі як Інтернет речей (IoT), бездротові сенсорні мережі (WSN) та системи передачі даних, стикаються з низкою викликів, які негативно впливають на їхню ефективність. Основними з цих викликів є забезпечення низької затримки передачі даних, оптимізація використання пропускної здатності, енергоефективність та масштабованість. У випадках 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, передача даних стає критично залежною 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 пропускної здатності мережі. У разі перевантаження або зростання попиту на ресурси зростають 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 враховуючи потреби інтегрованого підходу до одночасної оптимізації затримок, пропускної здатності та енергоефективності.

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

Огляд сучасних досліджень демонструє значний інтерес до використання машинного навчання для вирішення задач маршрутизації. Зокрема, у роботі [3] показано, що алгоритми підкріплювального навчання (Reinforcement Learning, RL) дозволяють ефективно адаптувати маршрути до змін у топології мережі, мінімізуючи затримки передачі; у [4] дослідили використання підходів машинного навчання для управління мережевим трафіком, акцентуючи увагу на необхідності обробки 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.

У статті [6] зосередилися на потенціалі використання інтелектуальних алгоритмів для підвищення продуктивності бездротових сенсорних мереж, акцентуючи 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.

В роботі [9] продемонстровано ефективність алгоритмів маршрутизації в динамічних мережах із використанням підходів навчання з підкріпленням. Дослідження [10] підкреслює

необхідність розробки стійких алгоритмів ML для маршрутизації у великих розподілених мережах, що враховують як мережеві, так і енергетичні обмеження.

Попри значний прогрес у цій галузі, залишаються актуальними питання впровадження цих підходів у масштабних розподілених системах. Сучасні дослідження вказують на необхідність розробки більш універсальних алгоритмів, здатних забезпечувати баланс між продуктивністю та енергоефективністю.

Метою цього дослідження є 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 існуючих методів, розробці алгоритму на основі ML для маршрутизації в умовах динамічних змін та оцінці його ефективності у порівнянні з традиційними підходами.

2. Аналіз та постановка задачі

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

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

У дослідженнях [3] та [7] було висвітлено перспективи використання методів машинного навчання (ML) для маршрутизації, які дозволяють системі адаптуватися до змінних умов, шляхом постійного навчання на основі нових даних. Зокрема, алгоритми підкріплювального навчання (RL) довели свою ефективність у вирішенні проблем, пов'язаних із непередбачуваною динамікою трафіку та дозволили зменшити середню затримку передачі даних у мережах до 20% у порівнянні з 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 розробки гібридних методів маршрутизації, які поєднують 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 потребують вирішення:

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

Постановка задачі цього дослідження базується на виявлених проблемах і спрямована на розробку нового алгоритму маршрутизації, який використовує машинне навчання для динамічної адаптації маршрутів у реальному часі. Основним завданням є досягнення оптимального співвідношення між швидкістю маршрутизації, продуктивністю мережі та енергоефективністю, враховуючи сучасні вимоги до безпеки та стійкості до атак.

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

Одним із найбільших викликів для цих методів є мобільні мережі, де вузли постійно змінюють своє місце розташування, 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 передачі даних. Наприклад, у мобільних *ad hoc* мережах (Mobile Ad Hoc Network, MANET) втрати зв'язку через переміщення вузлів стають критичним фактором, який унеможлиблює 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 значно зростають затримки, відбувається втрата пакетів, а продуктивність системи суттєво знижується. Цей недолік є особливо помітним 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 енергоресурсів окремих елементів мережі. У випадках, коли маршрути прокладаються через вузли з мінімальним залишком енергії, їхній вихід з ладу може викликати 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 значні втрати якості обслуговування.

Безпека також є слабким місцем традиційних підходів. Ці алгоритми не враховують можливі загрози, пов'язані з 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 в реальному часі.

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

3. Впровадження алгоритму пошуку шляху за критерієм мінімального часу проходження

Розподілені мережі є складною системою, 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 включають використання методів підкріплювального навчання, глибоких нейронних мереж та алгоритмів навчання з учителем. Наприклад, RL дозволяє маршрутизатору 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 всіх можливих дій a' .

Глибокі нейронні мережі використовуються для прогнозування трафіку в реальному часі, що дозволяє мінімізувати час передачі даних. Наприклад, прогнозування потоку даних може бути представлене 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 – активаційн функція, W_h – ваги для прихованого стану на попередньому кроці h_{t-1} , W_x – ваги для входних даних x_t , h_{t-1} – прихований стан на попередньому кроці часу, x_t – входні дані на поточному кроці часу, b – зміщення.

Для розробки алгоритму пошуку шляху за критерієм мінімального часу проходження було обрано підхід підкріплювального навчання. Основна ідея полягає в тому, щоб навчити агента (маршрутизатор) обирати маршрути, які мінімізують затримки передачі даних та враховують змінні мережеві умови.

Алгоритм включає три основні етапи:

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

$$R = -(w1 * d + w2 * b), \quad (3)$$

де R – значення винагороди. Воно є від'ємним, оскільки агент повинен мінімізувати як затримку d , так і використання пропускну здатності b , $w1, w2$ – вагові коефіцієнти, які визначають відносну важливість кожного з параметрів, d – затримка передачі даних. Це час, необхідний для передачі даних від відправника до одержувача. b – використання пропускну здатності каналу. Це кількість мережевих ресурсів, споживаних при передачі даних.

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

1. Зменшення затримки передачі: агент обирає маршрути, які забезпечують найшвидшу передачу даних.
2. Оптимізація використання ресурсів мережі: маршрути обираються таким чином, щоб уникати перевантаження мережі.

Роль вагових коефіцієнтів:

$w1, w2$ дозволяють адаптувати алгоритм до конкретних потреб мережі. Для реального часу (наприклад, відеодзвінків) важливішим є зменшення затримки, тому $w1$ може бути значно більшим за $w2$.

Для мереж із обмеженими ресурсами ваговий коефіцієнт $w2$ буде пріоритетним, оскільки важливо ефективно використовувати пропускну здатність.

Формула дозволяє 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 під специфічні умови або вимоги мережі.

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

На рисунку представлено схему алгоритму пошуку шляху за критерієм мінімального часу проходження в розподілених мережах, який базується на методах машинного навчання. Алгоритм включає наступні етапи:




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

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: Обробка даних про поточний стан мережі для визначення можливих рішень.

Оцінка можливих дій: Визначення, які маршрути є найбільш оптимальними 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.

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 вирішення задач маршрутизації у розподілених мережах. Застосування методів підкріплювального навчання дозволяє агенту адаптуватися до динамічних умов, що забезпечує покращення продуктивності мережі та зменшення затримок. В результаті, запропонована методологія може знайти практичне застосування в сучасних інформаційних системах, які вимагають високої швидкості обробки та передачі даних.

Для оцінки ефективності алгоритму було проведено 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 представлення сегменту топології мереж

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

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

Результати показали, що використання алгоритму підкріплювального навчання зменшує середній час передачі даних на 15% порівняно з традиційним алгоритмом Дейкстри. Візуалізація результатів наведена в таблиці 1 та на рисунку 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 (рисунк 4) відображено порівняння середнього часу затримки передачі 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) значно перевершує традиційний алгоритм Дейкстри за показником середнього часу затримки. Зокрема, використання Q-learning дозволяє зменшити час передачі 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, представлених на графіку (Рисунок 4), доцільно розглянути приклади практичного застосування запропонованого алгоритму в різних мережевих умовах і технологіях. Це дозволить підкреслити універсальність і практичну значущість отриманих результатів.

Запропонований алгоритм може бути успішно впроваджений у сфері Інтернету речей (IoT), де основними викликами є масштабованість і ефективність маршрутизації при обмежених ресурсах вузлів. У типових IoT-мережах, таких як розумні будинки або промислові системи, кожен вузол виконує завдання збору, обробки та передачі даних.




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

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

Перспективним напрямком використання запропонованого алгоритму є високонавантажені мережі, такі як центри обробки даних (ЦОД). У таких системах основним завданням 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 дозволить 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 більш раціональному 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 дозволяє оперативно оновлювати маршрути передачі 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 передачі даних. Наприклад, в умовах масових заходів, де трафік є надзвичайно щільним, запропонований алгоритм дозволяє оптимально розподілити навантаження між базовими станціями, уникаючи перевантажень та забезпечуючи високу якість обслуговування для всіх користувачів.

Таким чином, результати дослідження мають широкий спектр практичного застосування в різних сферах. Інтеграція алгоритму Q-learning у сучасні системи управління трафіком сприятиме покращенню ефективності роботи мереж, підвищенню їхньої стійкості до змін і оптимізації використання ресурсів. Подальші дослідження можуть зосередитися на розробці гібридних підходів, які об'єднують переваги Q-learning із традиційними методами маршрутизації, що дозволить ще більше розширити потенціал практичного застосування.

Отримані результати підтверджують ефективність використання машинного навчання для оптимізації маршрутизації. Запропонований алгоритм демонструє значні переваги у зменшенні затримок передачі 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 рамках цього дослідження, відкривають широкі можливості для подальшого вдосконалення запропонованого алгоритму та його адаптації до складніших умов сучасних мереж. Одним із ключових напрямків розвитку є інтеграція інших методів машинного навчання для підвищення точності прийняття рішень. Наприклад, використання глибоких нейронних мереж (DNNs) для моделювання складних залежностей у трафіку дозволить підвищити ефективність прогнозування та адаптації маршрутизації в умовах високої динаміки.

Застосування методів навчання з учителем (Supervised Learning) може забезпечити більш точне налаштування моделі для специфічних сценаріїв, наприклад, у мережах із заздалегідь відомими параметрами трафіку. Використання технік кластеризації (Unsupervised Learning) дозволить групувати вузли за рівнем навантаження або затримки, що сприятиме оптимальному розподілу ресурсів у розподілених мережах. Такі підходи доповнюють адаптивні можливості алгоритму Q-learning, зменшуючи залежність від виключно підкріплювального навчання.

Ще одним перспективним напрямком є розробка 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, дозволить 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 при зміні 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 процесу пошуку найкращих маршрутів. Генетичні алгоритми можуть використовуватися для початкової оптимізації параметрів навчання, таких як коефіцієнти винагороди або фактор дисконтування, що забезпечить швидше 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 врахування швидкості переміщення вузлів. Включення таких специфічних особливостей у модель маршрутизації дозволить значно 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. У свою чергу, це сприятиме ефективному впровадженню алгоритму в системи, які обробляють критично важливі дані, наприклад, у медичних або фінансових мережах.

Таким чином, розвиток запропонованого алгоритму може охоплювати як технічне вдосконалення самого процесу навчання, так і його адаптацію до нових технологічних викликів. Поєднання методів машинного навчання з традиційними підходами відкриває перспективи створення більш ефективних, стійких і масштабованих рішень для сучасних розподілених мереж.

Висновки

У межах цього дослідження було запропоновано алгоритм пошуку шляху за критерієм мінімального часу проходження, що базується на методах машинного навчання. Проведений аналіз сучасних підходів до оптимізації маршрутизації в розподілених мережах виявив низку суттєвих обмежень традиційних методів, таких як алгоритми Дейкстри чи Беллмана-Форда.

Основним недоліком цих алгоритмів є їх статичний характер, що не дозволяє їм ефективно адаптуватися до динамічних змін у топології мережі та трафіку. Запропонований підхід, заснований на підкріплювальному навчанні (Reinforcement Learning), продемонстрував здатність до

адаптивності та ефективного прийняття рішень у реальному часі, що дозволило подолати зазначені обмеження.

Практичне значення отриманих результатів полягає в можливості застосування розробленого алгоритму в різних сучасних мережевих середовищах, які характеризуються динамічністю змін і високими вимогами до продуктивності. Зокрема, запропонований підхід успішно вирішує завдання мінімізації середнього часу затримки передачі даних, що було підтверджено експериментальними результатами: затримка зменшилася на 15% порівняно з традиційними методами маршрутизації. Крім того, запропонований алгоритм дозволяє забезпечити більш ефективне використання мережевих ресурсів шляхом зниження 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 вимагають швидкої адаптації до змін у топології.

Подальший розвиток запропонованого підходу має значний потенціал для вдосконалення. Одним із ключових напрямків 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 є ще одним перспективним напрямком, який дозволить підвищити стійкість мереж до загроз, пов'язаних із маніпуляціями топологією чи несанкціонованим доступом до даних.

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

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

Список використаних літературних джерел

- [1]. José Craveirinha, João Climaco, 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, S. Bandery Str., 12, 79013, Lviv, 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*