

УДК 004.7:004.8

DOI <https://doi.org/10.32782/IT/2025-1-11>

Олександр ЗАЦ

аспірант Навчально-наукового інституту комп'ютерних наук та штучного інтелекту, Харківський національний університет імені В. Н. Каразіна, майдан Свободи, 6, м. Харків, Україна, 61022

ORCID: 0000-0002-7623-9187

Сергій ШМАТКОВ

доктор технічних наук, професор, професор кафедри комп'ютерних систем та робототехніки Навчально-наукового інституту комп'ютерних наук та штучного інтелекту, Харківський національний університет імені В. Н. Каразіна, майдан Свободи 4, м. Харків, Україна, 61022

ORCID: 0000-0002-0298-7174

Scopus Author ID: 57203141869

Вікторія СТІЛЕЦЬ

кандидат технічних наук, доцент кафедри комп'ютерних систем та робототехніки, Навчально-наукового інституту комп'ютерних наук та штучного інтелекту, Харківський національний університет імені В. Н. Каразіна, майдан Свободи, 6, м. Харків, Україна, 61022

ORCID: 0000-0002-2475-1496

Scopus Author ID: 58787462900

Григорій ЛІТВІНОВ

студент Навчально-наукового інституту комп'ютерних наук та штучного інтелекту, Харківський національний університет імені В. Н. Каразіна, майдан Свободи, 6, м. Харків, Україна, 61022

ORCID: 0009-0009-8842-8522

Бібліографічний опис статті: Зац, О., Шматков, С., Стрілець, В., Літвінов, Г. (2025). Модель маршрутизації в комп'ютерних мережах на основі графових нейронних мереж. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 73–81, doi: <https://doi.org/10.32782/IT/2025-1-11>

МОДЕЛЬ МАРШРУТИЗАЦІЇ В КОМП'ЮТЕРНИХ МЕРЕЖАХ НА ОСНОВІ ГРАФОВИХ НЕЙРОННИХ МЕРЕЖ

У комп'ютерних мережах ефективна маршрутизація є ключовим елементом для забезпечення надійної та швидкої передачі даних. Останнім часом набуває популярності використання графових нейронних мереж для вирішення задач маршрутизації. Графові нейронні мережі дозволяють моделювати складні взаємозв'язки в мережах та адаптуватися до змінних умов, що робить їх перспективним інструментом для оптимізації процесів передачі даних.

Мета роботи полягає у розробці ефективної моделі маршрутизації в комп'ютерних мережах для забезпечення зниження середньої затримки, покращення пропускної здатності та рівномірного розподілу навантаження між вузлами, з урахуванням динамічних умов мережі та складної топології.

Методологія. У дослідженні проаналізовано застосування графових нейронних мереж для розв'язання задачі маршрутизації. Задача маршрутизації представлена як задача машинного навчання, а саме класифікації ребер графа мережі, які формують оптимальний маршрут. Для побудови моделі оптимізації використані сучасні інструменти і технології, такі як Mininet, PyTorch Geometric та Ryu SDN Controller.

Наукова новизна. Запропонована модель маршрутизації в комп'ютерній мережі створена на основі згорткової графової нейронної мережі з двома згортковими шарами, що дозволяє врахувати складні топології мереж. Додавання шару регуляризації дозволило запобігти перенаванчання моделі.

Висновки. Розроблено модель маршрутизації в комп'ютерних мережах з використанням графових нейронних мереж. Результати тестування та інтеграції моделі довели, що GNN здатні ефективно вирішувати складні задачі маршрутизації, враховуючи динамічні зміни в мережі та складну топологію. Модель може бути використана для моніторингу та управління трафіком у реальних комп'ютерних мережах, особливо за умов великих навантажень або потенційних атак.

Ключові слова: комп'ютерна мережа, маршрутизація, графова нейронна мережа, згорткова графова нейронна мережа, машинне навчання.

Oleksandr ZATS

Postgraduate Student, Education and Research Institute of Computer Sciences and Artificial Intelligence, V.N.Karazin Kharkiv National University, 6, Svobody Squ., Kharkiv, Ukraine, 61022, zats2021ki51@student.karazin.ua

ORCID: 0000-0002-7623-9187

Serhiy SHMATKOV

Doctor of Technical Sciences, Professor, Professor at the Department of Computer Systems and Robotics, Education and Research Institute of Computer Sciences and Artificial Intelligence, V.N.Karazin Kharkiv National University, 6, Svobody Squ., Kharkiv, Ukraine, 61022, s.shmatkov@karazin.ua

ORCID: 0000-0002-0298-7174

Scopus Author ID: 57203141869

Viktoriia STRILETS

Candidate of Technical Sciences, Associate Professor at the Department of Computer Systems and Robotics, Education and Research Institute of Computer Sciences and Artificial Intelligence, V.N.Karazin Kharkiv National University, 6, Svobody Squ., Kharkiv, Ukraine, 61022, viktoriia.strilets@karazin.ua

ORCID: 0000-0002-2475-1496

Scopus Author ID: 58787462900

Hryhorii LITVINOV

Student, Education and Research Institute of Computer Sciences and Artificial Intelligence, V.N.Karazin Kharkiv National University, 6, Svobody Squ., Kharkiv, Ukraine, 61022, hryhorii.litvinov@student.karazin.ua

ORCID: 0009-0009-8842-8522

To cite this article: Zats, O., Shmatkov, S., Strilets, V., Litvinov, H. (2025). Model marshrutyzatsii v kompiuternykh merezhakh na osnovi hrafovykh neironnykh merezh [Routing model in computer networks based on graphic neural networks]. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 73–81, doi: <https://doi.org/10.32782/IT/2025-1-11>

ROUTING MODEL IN COMPUTER NETWORKS BASED ON GRAPHIC NEURAL NETWORKS

In computer networks, efficient routing is a key element for ensuring reliable and fast data transmission. Recently, the use of graph neural networks to solve routing problems has been gaining popularity. Graph neural networks allow to model complex relationships in networks and adapt to changing conditions, which makes them a promising tool for optimizing data transmission processes.

The purpose of the work is to develop an effective routing model in computer networks to ensure a reduction in average latency, improved throughput, and uniform load distribution between nodes, taking into account dynamic network conditions and complex topology.

Methodology. The study analyzes the use of graph neural networks to solve the routing problem. The routing problem is presented as a machine learning problem, namely, the classification of network graph edges that form the optimal route. Modern tools and technologies, such as Mininet, PyTorch Geometric, and Ryu SDN Controller, were used to build the optimization model.

Scientific novelty. The proposed routing model in a computer network is based on a convolutional graph neural network with two convolutional layers, which allows taking into account complex network topologies. Adding a regularization layer prevented overtraining of the model.

Conclusions. A routing model in computer networks using graph neural networks was developed. The achieved accuracy of the model was 97.85 %, high values of precision and recall demonstrate a low value of the 1st and 2nd kind errors. The results of testing and integration of the model proved that GNNs are able to effectively solve complex routing problems, taking into account dynamic changes in the network and complex topology. The model can be used to monitor and manage traffic in real computer networks, especially under conditions of high loads or potential attacks.

Key words: computer network, routing, graph neural network, convolutional graph neural network, machine learning.

Актуальність проблеми. Сучасні мережі передачі даних мають все більше внутрішньомережних обчислювальних можливостей та сервісів. Наприклад, технологія Software-Defined Networking (SDN) (Truong, 2015, с. 1205) передбачає відокремлення площини даних і площини керування, і рішення про маршрутизацію може прийматися централізовано, а не поетапно, з використання більшого обсягу інформації для кращих рішень щодо маршрутизації. Потоки трафіку, що проходять через такі мережі, обробляються різними типами проміжних блоків під час передачі. Щоб покращити безпеку та/або підвищити продуктивність мереж, потік даних також може проходити через обслуговуючі шлюзи або проміжні блоки для обробки, що стосується конкретного застосунку, наприклад, виявлення та запобігання вторгненням, кешування вмісту для зменшення затримки та мережевого трафіку, виявлення об'єктів із даних відеокамери, отриманих автономними транспортними засобами тощо (Lifan Mei, 2024, с. 1). У хмарних мережах для покращення продуктивності та стійкості проміжні блоки тиражуються по всій мережі та можуть бути еластично забезпечені на стандартних серверах за допомогою мережевої віртуалізації функцій (NFV) (Basta, 2014; Herrera, 2016).

Маршрутизація є критично важливим компонентом мережі передачі даних. Основною метою традиційної мережевої маршрутизації є перенаправлення трафіку користувачів до місць призначення з найменшою можливою затримкою, зберігаючи баланс навантаження та стійкість усієї мережі. Маршрутизація в мережах із вбудованими обчислювальними службами значно складніша. Тут необхідно знайти шлях для кожного потоку, який би одночасно мав достатню пропускну здатність і обчислювальні ресурси, щоб задовольнити трафік і обчислювальні вимоги потоку. Баланс навантаження та стійкості повинні підтримуватися як на каналах зв'язку, так і на обчислювальних вузлах. Додатково ускладнюється ситуація, коли спеціальні обчислювальні сервіси запроваджують різноманітні додаткові вимоги до маршрутизації.

Розподіл трафіку та обчислень безпосередньо впливає на баланс навантаження та стійкість усієї мережі. Тому існує необхідність у розробці й удосконаленні моделей, алгоритмів маршрутизації, які можуть вирішити ці виклики та вимоги.

Аналіз останніх досліджень і публікацій. Алгоритми маршрутизації мають довгий шлях розвитку, починаючи з класичних алгоритмів за вектором відстані, таких як RIP (Routing

Information Protocol), до сучасних протоколів стану зв'язку, таких як OSPF (Open Shortest Path First). Множина алгоритмів маршрутизації велика і різноманітна та відображає пошук та підвищення ефективності, масштабованості та надійності процесу передачі даних у мережі (Ujjwal Sinha, 2024, с. 2).

Ранні дослідження алгоритмів маршрутизації були зосереджені на розробці основних методів просування пакетів і визначення маршруту. Класичні алгоритми, такі як алгоритм Беллмана-Форда, алгоритм Дейкстри, алгоритм Флойда-Воршалла та дистанційно-векторний алгоритм, заклали основу для наступних удосконалень у розробці протоколу маршрутизації (Oluwaseyi Osunade, 2012, с. 15). Оскільки архітектура мереж постійно ускладнюється, були запропоновані складніші алгоритми, включаючи протоколи стану зв'язку, такі як OSPF і EIGRP (Akbor Aziz Susom, 2018; Ambresh G. Biradar, 2020), і протоколи векторів шляху, такі як BGP (Alotaibi Hamad, 2022, с. 3). Ці алгоритми відрізняються за своїм підходом до обчислення маршруту, розповсюдження оновлень і масштабованості, задовольняючи різноманітні вимоги мережі та топології.

Незважаючи на постійний розвиток, алгоритми маршрутизації стикаються з проблемами, які впливають на їх ефективність і надійність. Петлі маршрутизації, чорні діри та коливання маршруту є поширеними явищами, які можуть погіршити продуктивність і стабільність мережі. Проблеми з конвергенцією, викликані розкидом маршруту або зміною топології мережі, створюють додаткові труднощі для підтримки узгодженої інформації про маршрутизацію між вузлами мережі. Проблеми безпеки, такі як викрадення маршруту та атаки на відмову в обслуговуванні, ще більше ускладнюють розробку та роботу протоколів маршрутизації. Для вирішення цих проблем з'явилися нові підходи і технології, які можуть враховувати динамічні умови мережі, забезпечуючи безпеку та стабільність.

Методи машинного навчання, такі як навчання з підкріпленням і нейронні мережі, досліджуються для оптимізації рішень щодо маршрутизації та адаптації до змінної динаміки мережі (Mohamed Radzi, 2023; Bin Dai, 2021). Архітектура SDN (Truong, 2015, с. 1204) пропонує програмований контроль над мережевою інфраструктурою, забезпечуючи динамічну конфігурацію маршрутизації та проектування трафіку. Протоколи маршрутизації на основі блокчейну (Song Yu, 2023, с. 6) забезпечують підвищену безпеку та довіру в обміні інформацією про маршрутизацію, особливо в децентралізованих мережах.

У статті розглянуті підходи машинного навчання для маршрутизації в комп'ютерних мережах, зокрема графові нейронні мережі, які дають можливість описувати мережі передачі даних у вигляді графів і враховувати при цьому їх топологію та динамічні умови.

Мета дослідження полягає у розробці ефективної моделі маршрутизації в мережах передачі даних, яка забезпечує зниження середньої затримки, покращення пропускної здатності та рівномірний розподіл навантаження між вузлами, з урахуванням динамічних умов мережі та складної топології. Для забезпечення вимог модель запропоновано будувати на основі графових нейронних мереж.

Огляд графових нейронних мереж. Протягом багатьох років створювалися алгоритми і моделі маршрутизації для покращення доступності, продуктивності та масштабованості мереж. Одним із напрямків є поєднання технологій машинного навчання та алгоритмів маршрутизації.

Підходи машинного навчання з вчителем та з підкріпленням використовують як у централізованих алгоритмах маршрутизації, так і в алгоритмах децентралізованої маршрутизації. Серед цих підходів виділяють графові нейронні мережі (GNN), які дозволяють моделювати складні взаємозв'язки в мережах та адаптуватися до динамічних умов, що робить їх перспективним інструментом для задач маршрутизації (Zhou, 2018, с. 3). На відміну від традиційних нейронних мереж, які не враховують структуру даних, GNN дозволяють аналізувати мережі з урахуванням їхньої топології та вирішувати завдання, де структура даних відіграє ключову роль. Наприклад, GNN можуть вивчати зв'язок між топологією мережі, попитом на трафік і політикою маршрутизації і генерувати точні оцінки розподілу затримок і втрат для джерела/одержувача.

Концепція GNN була запропонована в роботі (Kawamoto, 2018, с. 2), у якій автори описали нейронну мережу для обробки даних, представлених у вигляді графів. У графі кожен вузол чином визначається власними характеристиками та зв'язаними з ним вузлами. Метою GNN є вивчення вбудованого (прихованого) стану $h_v \in R^S$, який містить інформацію про сусідні пов'язані вузли (оточення) для кожного вузла. Вбудований стан h_v є s -мірним вектором вузла v і може бути використаний для отримання виходу o_v , такого як мітка вузла. Нехай f є параметричною функцією (локальна функція переходу) використовується для всіх вузлів і оновлює стан вузла відповідно до вхідного оточення. Нехай g

буде локальною функцією виходу, яка описує, як саме отриманий вихід. Тоді h_v і o_v визначаються таким чином:

$$h_v = f(x_v, x_{co[v]}, h_{ne[v]}, x_{ne[v]}), \quad (1)$$

$$o_v = g(h_v, x_v), \quad (2)$$

де $x_v, x_{co[v]}, h_{ne[v]}, x_{ne[v]}$ – характеристики вузла v , ознаки його ребер, стани та особливості вузлів оточення v відповідно.

Нехай H, O, X і X_N – вектори, які описують усі стани, усі виходи, усі ознаки і всі характеристики вузла відповідно. Тоді у компактній формі:

$$H = F(H, X), \quad (3)$$

$$O = G(H, X_N), \quad (4)$$

де F – глобальна функція переходу і G – глобальна функція виходу, яка є згортою f і g для всіх вузлів у графі відповідно. Значення H є фіксованою точкою рівняння і однозначно визначається з припущення, що F є картою згортки.

У GNN використовується класична ітеративна схема для обчислення стану:

$$H^{t+1} = F(H^t, X), \quad (5)$$

де H^t позначає t ітерацію H . Динамічний процес (5) експоненціально швидко збігається до розв'язку рівняння (3) для будь-якого початкового значення $H(0)$.

Коли задана структура GNN, необхідно визначити параметри f і g . Маючи цільову інформацію (t_v для конкретного вузла) для спостереження, втрату можна записати таким чином:

$$loss = \sum_{i=1}^p (t_i - o_i), \quad (6)$$

де p – кількість контрольованих вузлів.

Алгоритм навчання базується на алгоритмі градієнтного спуску та складається з таких кроків:

- стани h_v^t ітеративно оновлюються за рівнянням (1) до часу T . Вони наближаються до фіксованої точки розв'язку рівняння (3): $H(T) \approx H$;

- градієнт вагових коефіцієнтів W обчислюється з функції втрати;

- вагові коефіцієнти W оновлюються відповідно до градієнта, обчисленого на останньому кроці.

Таким чином, початково GNN базується на механізмі передачі повідомлень, який оновлює стан певного вузла за інформацією від його оточення. Згодом у графові згорткові мережі був доданий шар згортки (GCN, графові згорткові нейронні мережі), і розроблено два види GNN: GCN на основі спектру та GCN на основі простору (Jiang, 2024, с. 12).

GCN на основі спектру визначають операцію згортки в спектральній області на основі методів обробки графового сигналу, вони не можуть обробляти напрямлені графи та мають низьку масштабованість у більшості випадків.

GCN на основі простору є більш гнучкими та загальними. Маючи відповідні функції оновлення, передачі повідомлень і зчитування, різні просторові варіанти GCN можуть бути представлені в єдиній формі нейронної мережі передачі повідомлень (MPNN).

GCN на основі спектру залежать від структури графа мережі. Таким чином, модель, навчена на конкретному графі, не може бути безпосередньо застосована до інших графових структур. Для вирішення цієї проблеми графова мережа уваги (GAT) (Jiang, 2024, с. 12) вводить механізм уваги, заснований на згортковій мережі графів і дозволяє моделі зосереджуватися на найбільш релевантній інформації. GAT має меншу складність і зосереджується лише на суміжних вузлах, не залежачи від інформації з усього графа. При застосуванні до нового графа GAT не потребує повторного навчання моделі.

Кожна з архітектур GNN (GCN, GAT) надає певні переваги залежно від умов мережі та завдань. GCN, які працюють шляхом застосування спектральних згорток над графовими структурами, ефективні для завдань, де потрібно отримати глобальну мережеву інформацію, наприклад, прогнозування затримки або перевантаження в широкій топології. Однак GCN часто мають проблеми з масштабованістю та обробкою

динамічних оновлень у реальному часі у великих мережах. GAT працюють краще в середовищах з високою мінливістю, таких як мобільні мережі, де певні з'єднання є більш критичними, ніж інші. Ця здатність динамічно зважувати важливість краю дозволяє GAT досягти успіху в мережах із частими змінами топології. Таким чином, GCN підходять для статичних або напівстатичних умов, GAT для високодинамічних мереж.

Виходячи з мети дослідження у роботі була обрана архітектура GCN.

Модель маршрутизації в комп'ютерній мережі. Модель маршрутизації ґрунтується на використанні GNN для ефективного навчання та обробки даних про топологію мережі. Основна задача моделі полягає у класифікації ребер графа, що визначає, чи входить конкретне ребро до складу оптимального маршруту між парою вузлів. Це дозволить не лише оптимізувати маршрутизацію, але й забезпечити більш точне розуміння структури мережі та її поведінки.

Для якісного навчання і тестування моделі на основі графових нейронних мереж важливим етапом є створення набору даних, який описує процес передачі даних у комп'ютерній мережі. У дослідженні такий набір даних був отриманий самостійно через створення моделі комп'ютерної мережі та її тестування за допомогою Mininet та Ryu SDN Controller.

Модель комп'ютерної мережі складається з 20 хостів та 5 комутаторів (рис. 1). Вузли джерела трафіку h_1-h_{10} відповідають за генерування різних видів трафіку в мережі. Вузли




Рис. 1. Схема топології комп'ютерної мережі

приймачі трафіку (SINK) $h_{11}-h_{20}$ є кінцевими точками для трафіку.

Комутатори s_1-s_5 підтримують протокол STP (Spanning Tree Protocol) для уникнення мережних циклів та забезпечення надлишковості з'єднань. Вузли SRC з'єднуються з комутаторами, і пропускна здатність кожного з'єднання обмежена до 10 Мбіт/с. Вузли SINK з'єднуються з комутаторами з пропускною здатністю 10 Мбіт/с. Комутатори з'єднані між собою для забезпечення надійності і резервування, і ці з'єднання мають більшу пропускну здатність 20 Мбіт/с, що дозволяє їм обробляти великий обсяг трафіку між комутаторами та забезпечує альтернативні шляхи передачі.

Збір мережних даних був проведений за допомогою симулятора Mininet, у якому було реалізовано кілька тестових сценаріїв навантаження:

- моделювання TCP SYN атаки. Цей сценарій дозволяє оцінити стійкість мережі до розподілених DoS-атак та ефективність обробки атакуючого трафіку комутаторами. TCP SYN атака створює масивний трафік, що імітує спроби встановлення з'єднань, і може викликати перевантаження ресурсів на вузлах чи комутаторах;
- перевірка доступності вузлів за допомогою ICMP пінгу. Цей сценарій дозволяє визначити вплив різних сценаріїв трафіку на загальну продуктивність мережі;
- оцінка продуктивності комутаторів і обробки з'єднань із високою частотою передачі пакетів. Цей сценарій дає змогу визначити, наскільки ефективно комутатори маршрутизують трафік із низькою затримкою та високою частотою пакетів;
- додаткові сценарії тестування із різними параметрами інтенсивності та обсягу пакетів. Це дозволило проаналізувати поведінку мережі при комбінованих типах навантаження і визначити можливі вузькі місця в обробці трафіку.

За допомогою Ryu Controller, який реалізує табличну модель маршрутизації, активованого на комутаторах протоколу STP, що динамічно виявляє петлі у мережі та автоматично блокує зайві шляхи, залишаючи лише один активний маршрут між вузлами, було створено потрібний набір даних. Отриманий датасет NetData включав інформацію про кожен зв'язок у мережі, зокрема: часову мітку, ідентифікатори комутаторів і хостів, пропускну здатність, затримку передачі та рівень втрат пакетів.

На етапі попередньої підготовки даних створюється граф для кожного рядка вхідного набору даних NetData. Кожен рядок описує множину ребер, а також їх параметри, такі як пропускна здатність. У процесі побудови графа задається

список усіх ребер з мітками, що вказують на їхню приналежність до маршруту. Для кожного ребра визначається, чи є воно частиною оптимального маршруту, і присвоюється відповідна мітка: 1, якщо ребро входить до маршруту, та 0, якщо не входить. Це дозволило сформуванати набір даних, необхідний для навчання моделі бінарної класифікації на основі GCN.

Архітектура моделі GNNRoute складалася з таких основних компонентів:

- GCNConv шари: два графових згорткових шари для обробки інформації про вузли та їх взаємозв'язки;
- Dropout: регуляризація для запобігання перенавчання;
- лінійний (повнозв'язний) шар виконує класифікацію комбінованих ембедінгів вузлів, що з'єднують ребра, для визначення їхньої важливості в маршруті.

Така архітектура забезпечила здатність моделі враховувати як локальні властивості вузлів, так і глобальну структуру графа.

Навчання моделі GNNRoute здійснювалося з такими параметрами: критерій оптимізації – бінарна крос-ентропійна функція втрат; метод оптимізації Adam, який забезпечує швидке та стабільне навчання моделі. У результаті навчання були отримані показники ефективності моделі та її здатності класифікувати оптимальні маршрути в мережі. Оцінка базується на показниках втрати (Loss), точності (Accuracy), а також метрик Precision, Recall і F1 Score (табл. 1).

На початкових етапах (епоха 10) втрата складає 0.3091, що вказує на значні помилки моделі під час прогнозування. Протягом тренування значення втрати поступово зменшується, досягаючи значення 0.0215 на 180-й епосі. Це свідчить про те, що модель успішно навчається, а її прогнози стають дедалі точнішими.

Точність значно зростає протягом навчання. З 19.09 % на 10-й епосі вона підвищується до 97.85 % на 180-й епосі, що є показником високої якості прогнозів моделі. Відсутність значного зниження точності на останніх етапах (після 180-ї епохи) свідчить про стабільність моделі та відсутність перенавчання.

Precision залишається високим протягом усього навчання, поступово зростаючи від 0.7564 (епоха 10) до 0.8135 (епоха 170). Це свідчить про те, що модель рідко визначає неправильні ребра як частину маршруту.

Recall також демонструє позитивну динаміку, підвищуючись від 0.6870 на початку навчання до 0.799 на 180-й епосі. Високі значення Recall показують, що модель майже не пропускає правильні ребра в маршрутах.

Таблиця 1

Значення показників якості протягом навчання

Епоха	Loss	Accuracy	Precision	Recall	F1 Score
10	0.3091	0.6909	0.7564	0.6870	0.6720
30	0.1028	0.8972	0.8050	0.7780	0.7796
50	0.0451	0.9549	0.8074	0.7910	0.7921
70	0.0391	0.9609	0.8147	0.8000	0.8018
90	0.0367	0.9633	0.8135	0.7980	0.7998
100	0.0404	0.9596	0.8138	0.7980	0.7998
120	0.0425	0.9575	0.8125	0.8000	0.8014
140	0.0257	0.9743	0.8108	0.7960	0.7979
160	0.0413	0.9587	0.8135	0.7990	0.8008
180	0.0215	0.9785	0.8117	0.7990	0.8004
200	0.0336	0.9664	0.8115	0.8020	0.8026

F1 Score, як збалансований показник між Precision і Recall, зростає з 0.6720 до 0.8055, що відображає загальну якість класифікації моделі.

На останніх епохах (після 180-ї) спостерігається стабілізація результатів. Метрики Precision, Recall і F1 Score змінюються незначно, що свідчить про досягнення моделлю свого потенціалу навчання.

Для тестування навчена модель була інтегрована в Ryu SDN Controller, який відстежує стан комутаторів, портів та зв'язків між ними. При цьому інформація про трафік збирається та оновлюється в режимі реального часу.

Модель GNNRoute завантажується при ініціалізації контролера та використовується для передбачення оптимальних маршрутів на основі зібраних даних про топологію та поточний стан мережі.

При отриманні пакету, контролер визначає його тип (TCP, UDP, ICMP, ARP) та викликає функцію для встановлення відповідних правил маршрутизації. Використовуючи інформацію

з GNNRoute, контролер встановлює правила потоку на комутаторах для оптимальної маршрутизації трафіку.

Було проведено тестування комп'ютерної мережі з використанням запропонованої моделі та без неї (рис. 2).

Лінія синього кольору ілюструє поведінку портів вузлів без використання SDN (без GNNRoute). Навантаження на порти є вищим, ніж у сценарії з SDN, і коливається в діапазоні 85–95 Mbps. Спостерігається сильна нестабільність, значні пікові стрибки та коливання у навантаженні.

Лінія зеленого кольору відображає мережу з активним використанням SDN (з GNNRoute). Навантаження значно нижче, ніж у сценарії без SDN, і знаходиться в діапазоні 75–85 Mbps. Коливання значно менші, навантаження є більш стабільним завдяки оптимізації трафіку SDN-контролером.

Таким чином, тестування моделі показало її ефективність під час оптимізації маршрутизації в мережі.




Рис. 2. Графік порівняння навантаження в комп'ютерній мережі

Висновки. У роботі запропонована модель маршрутизації у комп'ютерній мережі GNNRoute, яка використовує переваги графових нейронних мереж.

Етап підготовки даних та архітектурні рішення, закладені у моделі GNNRoute, дозволяють точно прогнозувати оптимальні маршрути в складних мережових топологіях. Поєднання даних про структуру графа, пропуску здатність ребер та їхню класифікацію

створює основу для ефективного управління трафіком і покращення загальної продуктивності мережі.

Модель демонструє ефективне навчання з високими показниками точності, Precision, Recall і F1 Score. Низька втрата та висока точність після 180-ї епохи вказують на те, що подальше навчання може бути неефективним і що модель готова до застосування у практичних задачах прогнозування маршрутів у мережах.

ЛІТЕРАТУРА:

1. Truong N.B., Lee G.M., Ghamri-Doudane Y. Software defined networking-based vehicular Adhoc Network with Fog Computing. *Proceedings of the 2015 IFIP/IEEE International Symposium on Integrated Network Management, IM 2015*, pp. 1202–1207. DOI: <https://doi.org/10.1109/INM.2015.7140467>
2. Lifan Mei, Jinrui Gou, Jingrui Yang, Yujin Cai, Yong Liu. On Routing Optimization in Networks with Embedded Computational Services. *IEEE Transactions on Network and Service Management*, 2024. <https://doi.org/10.48550/arXiv.2210.03338>
3. Basta A., Kellerer W., Hoffmann M., Morper H.J., Hoffmann K. Applying nfv and sdn to lte mobile core gateways, the functions placement problem. *Proceedings of the 4th workshop on All things cellular: operations, applications, & challenges*, 2014, pp. 33–38.
4. Herrera J.G., Botero J.F. Resource allocation in nfv: A comprehensive survey. *IEEE Transactions on Network and Service Management*, 2016, vol. 13, no. 3, pp. 518–532.
5. Ujjwal Sinha, Vikas Kumar, Shubham Kumar Singh. Routing Algorithms: A Reiew. *ArXiv, Computer Science, Networking and Internet Architecture*, 2024. URL: <https://arxiv.org/pdf/2403.11228>
6. Oluwaseyi Osunade. A Packet Routing Model for Computer Networks. *International Journal of Computer Network and Information Security*, 2012, 4, pp. 13–20. DOI: <https://doi.org/10.5815/ijcnis.2012.04.02>
7. Akbor Aziz Susom. Effectiveness of Routing Protocols for Different Networking Scenarios. *Advances in Science Technology and Engineering Systems Journal*, 2018, vol. 3, no. 4, pp. 112–121. DOI: <https://doi.org/10.25046/aj030412>
8. Ambresh G. Biradar. A Comparative Study on Routing Protocols: RIP, OSPF and EIGRP and Their Analysis Using GNS-3. *5th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE)*, 2020. DOI: <https://doi.org/10.1109/ICRAIE51050.2020.9358327>
9. Alotaibi Hamad, Gregory Mark, Li Shuo. Multidomain SDN-Based Gateways and Border Gateway Protocol. *Journal of Computer Networks and Communications*, 2022. DOI: <https://doi.org/10.1155/2022/3955800>
10. Mohamed Radzi, Nurul Asyikin, Mohd Azmi, Kaiyisah Hanis, Abdullah, Fairuz, Wan Ahmad, Wan Siti Halimatul Munirah. A New Machine Learning-based Hybrid Intrusion Detection System and Intelligent Routing Algorithm for MPLS Network. *International Journal of Advanced Computer Science and Applications*, 2023, vol. 14, no. 4, pp. 94–107. DOI: <https://doi.org/10.14569/IJACSA.2023.0140412>
11. Bin Dai, Yuanyuan Cao, Zhongli Wu, Zhewei Dai, Ruyi Yao, Yang Xu. Routing optimization meets Machine Intelligence: A perspective for the future network. *Neurocomputing*, 2021, vol. 459, pp. 44–58, <https://doi.org/10.1016/j.neucom.2021.06.093>
12. Song Yu, Ao Xiong, Xuesong Qiu, Shaoyong Guo, Dong Wang, Da Li, Xin Zhang, Yue Kuang. A Blockchain-Based Method for Optimizing the Routing of High-Frequency Carbon-Trading Payment Channels. *Electronics*, 2023, no. 12: 2586. <https://doi.org/10.3390/electronics12122586>
13. Zhou J., Cui G., Zhang Z., Yang C., Liu Z., Sun M. Graph Neural Networks: A Review of Methods and Applications. *ArXiv, Computer Science, Networking and Internet Architecture*, 2018. DOI: <https://doi.org/10.48550/arXiv.1812.08434>
14. Kawamoto T., Tsubaki M., Obuchi T. Mean-field theory of graph neural networks in graph partitioning. *NeurIPS*, 2018, pp. 4366–4376.
15. Jiang W., Han H., Zhang Y., Wang J., He M., Gu W., Mu J., Cheng X. Graph Neural Networks for Routing Optimization: Challenges and Opportunities. *Sustainability* 2024, 16, 9239. <https://doi.org/10.3390/su16219239>

REFERENCES:

1. Truong, N. B., Lee, G. M., Ghamri-Doudane, Y. (2015). Software defined networking-based vehicular Adhoc network with Fog computing. *Proceedings of the 2015 IFIP/IEEE International Symposium on Integrated Network Management, IM 2015*, pp. 1202–1207. DOI: <https://doi.org/10.1109/INM.2015.7140467>
2. Lifan Mei, Jinrui Gou, Jingrui Yang, Yujin Cai, Yong Liu. (2024). On Routing Optimization in Networks with Embedded Computational Services. *IEEE Transactions on Network and Service Management*. Retrieved from: <https://doi.org/10.48550/arXiv.2210.03338>
3. Basta, A., Kellerer, W., Hoffmann, M., Morper, H. J., Hoffmann, K. (2014). Applying nfv and sdn to lte mobile core gateways, the functions placement problem. *Proceedings of the 4th workshop on All things cellular: operations, applications, & challenges*, pp. 33–38.
4. Herrera, J. G., Botero, J. F. (2016). "Resource allocation in nfv: A comprehensive survey. *IEEE Transactions on Network and Service Management*, vol. 13, no. 3, pp. 518–532.
5. Ujjwal Sinha, Vikas Kumar, Shubham Kumar Singh. (2024). Routing Algorithms: A Review. *ArXiv, Computer Science, Networking and Internet Architecture*. Retrieved from: <https://arxiv.org/pdf/2403.11228>
6. Oluwaseyi Osunade. (2012). A Packet Routing Model for Computer Networks. *International Journal of Computer Network and Information Security*, 4, pp. 13–20. DOI: <https://doi.org/10.5815/ijcnis.2012.04.02>
7. AkborAzizSusom. (2018). Effectiveness of Routing Protocols for Different Networking Scenarios. *Advances in Science Technology and Engineering Systems Journal*, vol. 3, no. 4, pp. 112–121. DOI: <https://doi.org/10.25046/aj030412>
8. Ambresh, G. Biradar. (2020). A Comparative Study on Routing Protocols: RIP, OSPF and EIGRP and Their Analysis Using GNS-3. *5th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE)*. DOI: <https://doi.org/10.1109/ICRAIE51050.2020.9358327>
9. Alotaibi Hamad, Gregory Mark, Li Shuo. (2022). Multidomain SDN-Based Gateways and Border Gateway Protocol. *Journal of Computer Networks and Communications*. DOI: <https://doi.org/10.1155/2022/3955800>
10. Mohamed Radzi, Nurul Asyikin, Mohd Azmi, Kaiyisah Hanis, Abdullah, Fairuz, Wan Ahmad, Wan Siti Halimatul Munirah. (2023). A New Machine Learning-based Hybrid Intrusion Detection System and Intelligent Routing Algorithm for MPLS Network. *International Journal of Advanced Computer Science and Applications*, vol. 14, no. 4, pp. 94–107. DOI: <https://doi.org/10.14569/IJACSA.2023.0140412>
11. Bin Dai, Yuanyuan Cao, Zhongli Wu, Zhewei Dai, Ruyi Yao, Yang Xu. (2021). Routing optimization meets Machine Intelligence: A perspective for the future network. *Neurocomputing*, vol. 459, pp. 44–58, <https://doi.org/10.1016/j.neucom.2021.06.093>
12. Song, Yu, Ao, Xiong, Xuesong, Qiu, Shaoyong, Guo, Dong, Wang, Da, Li, Xin, Zhang, Yue, Kuang. (2023). A Blockchain-Based Method for Optimizing the Routing of High-Frequency Carbon-Trading Payment Channels. *Electronics*, 12, no. 12: 2586. <https://doi.org/10.3390/electronics12122586>
13. Zhou, J., Cui, G., Zhang, Z., Yang, C., Liu, Z., Sun, M. (2018). Graph Neural Networks: A Review of Methods and Applications. *ArXiv, Computer Science, Networking and Internet Architecture*. DOI: <https://doi.org/10.48550/arXiv.1812.08434>
14. Kawamoto, T., Tsubaki, M., Obuchi, T. (2018). Mean-field theory of graph neural networks in graph partitioning. *NeurIPS 2018*, pp. 4366–4376.
15. Jiang, W., Han, H., Zhang, Y., Wang, J., He, M., Gu, W., Mu, J., Cheng, X. (2024). Graph Neural Networks for Routing Optimization: Challenges and Opportunities. *Sustainability*, 16, 9239. <https://doi.org/10.3390/su16219239>