

DOI: <https://doi.org/10.15276/ict.01.2024.04>

УДК 004.7

Удосконалення моделі графової нейронної мережі для задач імітаційного моделювання

Буюклі Віктор Сергійович¹⁾

Аспірант каф. Комп'ютерних інтелектуальних систем та мереж
ORCID: <https://orcid.org/0000-0001-7384-2290>; vktr.buyukli@gmail.com

Науменко Роман Іванович¹⁾

Аспірант каф. Комп'ютерних інтелектуальних систем та мереж
ORCID: <https://orcid.org/0009-0003-7612-1773>; lwoodooz7@gmail.com

Тішин Петро Метгалинович¹⁾

Канд. фізико-математич. наук, доцент каф. Комп'ютерних інтелектуальних систем та мереж
ORCID: <https://orcid.org/0000-0003-2506-5348>; petrmittal@gmail.com. Scopus Author ID: 57190400970

¹⁾ Національний університет «Одеська політехніка», пр. Шевченка, 1. Одеса, 65044, Україна

АНОТАЦІЯ

В умовах стрімкого зростання мережевих систем та їхньої складності завдання точного моделювання мережевих параметрів стає критично важливим для ефективного управління та оптимізації мережевої інфраструктури. У цьому контексті, робота фокусується на розширеній версії моделі RouteNet, яка розширює можливості моделювання за рахунок врахування характеристик вузлів мережі, таких як розміри черг. Оригінальна модель RouteNet демонструє хороші результати в передбаченні затримок і втрат пакетів у однорідних мережевих умовах, проте має суттєві обмеження, коли мова йде про варіації характеристик вузлів. Розширення моделі передбачає інтеграцію механізмів для роботи з вузлами, що мають різні конфігурації, що дозволяє моделі краще відображати реальні умови мережі. Це включає врахування параметрів вузлів, таких як розміри черг, які можуть суттєво відрізнятися в реальних мережах. Таке удосконалення робить модель більш адаптивною і точною в умовах, що близькі до реальних сценаріїв мережевої роботи. У рамках дослідження проведено ряд експериментів, що включають навчання та оцінку продуктивності нової моделі, її порівняння з оригінальною версією, а також аналіз отриманих результатів. Важливим аспектом є оцінка значущості отриманих результатів для мережевих досліджень, зокрема для задач імітаційного моделювання комп'ютерних мереж. Це дозволяє не лише підвищити точність моделювання, але й забезпечити більш ефективні рішення для управління та оптимізації сучасних мережевих систем, що є ключовим для їхньої стабільної та продуктивної роботи.

Ключові слова: графова нейронна мережа; RouteNet; мережеві моделі; затримка; втрати пакетів; черги вузлів; імітаційне моделювання; машинне навчання

Актуальність. Останні досягнення в галузі штучного інтелекту [1] привели до нової ери методів машинного навчання, таких як глибоке навчання [2, 3]. Це викликало інтерес серед мережевої спільноти до спроби скористатися перевагами цих нових методів для розробки моделей, в тому числі орієнтованих на моделювання комп'ютерних мереж з використанням нейронних мереж (НМ) [4, 5].

Одним із прикладів застосування нових підходів є оригінальна версія RouteNet [6], розроблена для прогнозування ключових параметрів мережі, таких як затримка та втрата пакетів. Оригінальна версія RouteNet успішно справляється з моделюванням затримок і втрат пакетів, використовуючи загальні параметри вузлів. У той же час такий підхід обмежує її здатність до точного моделювання в умовах із різними характеристиками вузлів.

У роботі представлена розширена версія RouteNet, яка враховує відмінності у характеристиках вузлів, таких як розміри черг. Це дозволяє більш точно відображати поведінку мережі в реальних умовах, де вузли можуть мати різні розміри черг, що впливає на затримки та втрати пакетів.

Метою роботи є розробка та оцінка розширеної версії моделі RouteNet, яка включає врахування характеристик вузлів мережі, таких як розміри черг. Запропонована модель може покращити точність передбачень затримок і втрат пакетів шляхом впровадження додаткових даних. Важливою частиною дослідження є перевірка здатності моделі узагальнювати результати на нові топології та сценарії, не включені в набір даних для навчання. Таким чином, метою є створення моделі, яка буде не тільки більш точною, але й більш універсальною, здатною адаптуватися до різних умов мережі та сценаріїв трафіку.

This is an open access article under the CC BY license (<https://creativecommons.org/licenses/by/4.0/deed.uk>)

Основна частина. RouteNet – це модель на основі графової нейронної мережі (GNN), яка оцінює показники продуктивності мережі між джерелом і отримувачем. Основна перевага моделей GNN порівняно з іншими архітектурами нейронних мереж (повнозв’язані, згорткові, рекурентні) полягає у їх здатності “розуміти” та використовувати реляційні патерни між елементами графа, а основним способом представлення даних, пов’язаних із мережею, є форма графів. Це пояснює, чому RouteNet здатна узагальнювати дані для мережевих топологій маршрутизації та вхідного трафіку, які не зустрічалися під час навчання.

RouteNet здатна поширювати будь-яку схему маршрутизації через топологію мережі та абстрагувати значущу інформацію про поточний стан мережі. На Рис. 1 представлено схематичне зображення моделі.

RouteNet отримує на вхід: задану топологію; схему маршрутизації джерело-призначення (тобто взаємозв’язки між кінцевими шляхами та лінками) матрицю трафіку (визначену як пропускна здатність між кожною парою вузлів у мережі). І зрештою генерує показники продуктивності відповідно до поточного стану мережі (наприклад, затримки на кожному шляху або джиттер). Для досягнення цього RouteNet використовує вектори фіксованого розміру, які кодують стани шляхів та лінків, і поширює інформацію між ними відповідно до схеми маршрутизації. Тобто основна ідея, що лежить в основі RouteNet, базується на взаємозв’язках між станом шляхів і зв’язків у мережах. Інтуїтивно зрозуміло, що шлях залежить від зв’язків, через які він проходить, а зв’язок, своєю чергою, залежить від усіх шляхів, що перетинають цей зв’язок. Таким чином, RouteNet отримує початкові стани шляхів і зв’язків (закодовані у вигляді векторів фіксованого розміру) і виконує ітеративний алгоритм передачі повідомлень між цими станами відповідно до вхідної топології та схеми маршрутизації. На кожній ітерації стани зв’язків і шляхів оновлюються новою інформацією, об’єднаною відповідно до структури графа. Після певної кількості ітерацій стани шляхів використовуються для оцінки кінцевих мережевих показників продуктивності [6].

В оригінальній і запропонованій моделях використовуються графова і рекурентні нейронні мережі (RNN), які використовують різні структури для роботи з даними, що впливає на їхні математичні формули.

Структура вхідних даних.

GNN працює з графами: $G=(V,E)$, де V – набір вершин, E – набір ребер. Дані визначаються через зв’язки між об’єктами.

RNN працює з послідовностями: $x=\{x_1,x_2,\dots,x_T\}$, де x_T – елемент послідовності на момент часу t .

Для GNN оновлення стану вершини:

$$h_v^{(l+1)} = \sigma \left(W^{(l)} h_u^{(l)} + \sum_{u \in N(v)} \frac{1}{|N(v)|} W^{(l)} h_u^{(l)} \right) , \quad (1)$$

де $h_v^{(l+1)}$ – вектор стану вершини v на l -му шарі, $N(v)$ – сусіди вершини v , $W^{(l)}$ – матриця ваг, σ – активаційна функція.

Для RNN оновлення стану для кожного моменту часу:

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

де: h_t – прихований стан в момент часу t , x_t – вхід на t -му кроці, W_x і W_h – матриці ваг.



Рис. 1. Загальна схема оригінальної моделі RouteNet

Як результат обчислень (вивід): у GNN глобальний або вузловий вивід, що залежить від структури графа:

$$y = f(\{h_v^{(L)} \mid v \in V\}), \tag{3}$$

де L – кількість шарів GNN, а f – функція агрегації.

В той же час у RNN вивід на кожному кроці часу або фінальний вивід після обробки всієї послідовності:

$$y_t = f(h_t) \text{ або } y = f(h_T), \tag{4}$$

де h_t – стан на фінальному кроці T .

GNN враховує зв'язки між вузлами в графі, що дозволяє враховувати інформацію від сусідніх вузлів. RNN враховує тимчасову залежність шляхом передавання стану через час.

Тобто GNN орієнтована на графи, які використовується для задач, де важлива структура взаємодій. RNN же працює з послідовностями, зберігає пам'ять про попередні стани через час.

З оригінальною архітектурою RouteNet не може моделювати особливості різних пристроїв пересилання (наприклад, планування, розміри черг), які можуть мати значний вплив на продуктивність мережі. Природним способом впровадження концепції мережевого вузла (тобто пристрою пересилання) є додавання сутності вузла в архітектуру RouteNet. Аналогічно станам, пов'язаним із кожним шляхом і зв'язком, можна ввести стан, пов'язаний із кожним мережевим вузлом.

У новій архітектурі передачі повідомлень стан кожного вузла (закодований у вигляді вектора фіксованого розміру) оновлюється на основі інформації від усіх шляхів, що проходять через цей вузол. Спочатку виконується поелементне сума всіх станів шляхів, пов'язаних із вузлом, а потім результат використовується як вхідні дані для рекурентної нейронної мережі. Крім того, замість оновлення станів шляхів тільки на основі інформації про зв'язки, використовується як стан зв'язків, так і вузлів. У оригінальному дизайні RouteNet (Рис. 2) стани шляхів оновлюються рекурентною нейронною мережею, яка приймає в якості вхідних даних послідовність станів зв'язку, пов'язану з кожним шляхом. У новій архітектурі встановлюються стани вузлів у ці послідовності та чергуються зі станами зв'язків, що стосуються кожного шляху (тобто вузол1-зв'язок1-вузол2-зв'язок2 і т.д.) (Рис. 2).

На Рис. 2 представлені наступні елементи: *стани шляхів* – стан кожного шляху в мережі, що представляється у вигляді векторів фіксованого розміру; *стани зв'язків* – стан кожного зв'язку між вузлами, закодований у вигляді векторів; *по-шляху* та *по-зв'язку* – обчислення, які виконуються для кожного шляху та зв'язку відповідно; *стани вузлів* – додаються як новий




Рис. 2. Спрощена схема передачі повідомлень оригінальної (ліворуч) та розширеної (праворуч) моделі RouteNet

елемент у моделі, що дозволяє враховувати індивідуальні характеристики кожного вузла (*no-vuzlu*); *чергування* – процес об'єднання станів вузлів зі станами зв'язків і шляхів, що дозволяє моделі враховувати складні взаємодії в мережі; *RNN_i* – модель використовує рекурентні нейронні мережі для обробки даних різних компонентів мережі (вузли, шляхи, зв'язки).

Як і в оригінальній RouteNet, після завершення передачі повідомлень використовуються кінцеві стани шляхів для оцінки показників продуктивності мережі від джерела до одержувача. Це робиться шляхом застосування функції читання (*readout function*) [7], реалізованої у вигляді прямої нейронної мережі, до кожного стану шляху. Таким чином, завдання навчання в розширеному RouteNet полягає в знаходженні оптимальних параметрів чотирьох функцій: RNN_N , RNN_P , RNN_L , функції читання.

Розширена модель додає рівень деталізації, включаючи стан вузлів у процес моделювання. Це дозволяє моделі більш точно імітувати мережеві умови, враховуючи такі фактори, як черги на вузлах, що впливають на затримки і втрати пакетів. Таким чином, розширена модель забезпечує кращу узагальненість і точність прогнозів у складних мережевих умовах.

Для навчання та тестування моделі використовуються два топологічних набори даних: 24-вузлова топологія Geant2 [8] і 14-вузлова топологія NSFNet [9]. Ці набори даних зібрані за допомогою кастомного пакетного симулятора, заснованого на OMNeT++ [10]. Симулятор модифікований для підтримки різних розмірів черг вузлів та інших характеристик мережі. Кожен набір даних містить інформацію про топологію мережі, схему маршрутизації, матрицю трафіку і метрики мережевої продуктивності, такі як середня затримка і втрата пакетів. Всього зібрано 600000 зразків, що забезпечує широкий охоплення діапазону значень затримок і різних сценаріїв навантаження. Це дозволяє отримати надійні і репрезентативні результати для оцінки продуктивності моделі. Використовуються зразки з топології Geant2 для навчання та NSFNet для валідації та тестування, оскільки узагальнення на різні топології є характеристикою оригінального RouteNet, яку також потрібно відтворити у будь-якій новій архітектурі. Вибір Geant2 для навчання та NSFNet для оцінки не є довільним. В ході експериментів встановлено, що для кращого узагальнення RouteNet потрібно навчати на топологіях, принаймні таких же великих, як і ті, що використовуються для оцінки. Тому модель навчається на топології з 24 вузлів (Geant2), яка більша, ніж 14-вузлова топологія NSFNet.

Для оцінки ефективності запропонованого рішення необхідно порівняти нову модель з оригінальним RouteNet, і оцінити ефективність нового рішення. Тобто надає воно хороші оцінки чи ні. Для цієї мети вибрані 100000 зразків з Geant2 та 100000 з NSFNet, які складають тестовий набір даних. Використовуються кілька метрик для оцінки помилки передбачень щодо справжніх значень, таких як абсолютна помилка (MAE), середня абсолютна відносна помилка (MARE) і кореляція Пірсона. У задачі не можна використовувати лише одну метрику, тому що кожна з них може втратити важливу інформацію. Наприклад, можна мати хорошу середню абсолютну помилку, але великі відносні помилки за малих значень затримки. З іншого боку, мала відносна помилка може приховувати те, що модель робить не точні прогнози при великих значеннях затримки. Оцінка результатів (Таблиця) показує покращення порівняно з оригінальною моделлю RouteNet. Розширена модель досягла коефіцієнта кореляції Пірсона 0.98 на даних NSFNet і 0.91 на даних Geant2. Оригінальна модель показала гірші результати з коефіцієнтом кореляції близько 0.8 на Geant2 і 0.74 на NSFNet.

Таблиця показує переваги розширеної моделі, яка враховує різні характеристики вузлів. Покращення кореляційних коефіцієнтів свідчить про здатність розширеної моделі точніше передбачати продуктивність мережі, навіть у сценаріях, що не були включені в навчальний набір даних. Результати свідчать про те, що розширена модель здатна давати значно більш точні прогнози порівняно з оригінальною версією RouteNet, оскільки вона враховує інформацію про розміри черг на вузлах. Також можна спостерігати, що вона успішно узагальнює на сценарії NSFNet, незважаючи на те, що не бачила прикладів із цієї топології під час навчання.

Таблиця. Порівняльна таблиця метрик моделей

Модель	Набір даних	MAE	MARE	Коеф. кор. Пірсона
Оригінальна	Geant2	0.085	17.97 %	0.802
Розширена	Geant2	0.013	2.23 %	0.910
Оригінальна	NSFNet	0.140	26.38 %	0.736
Розширена	NSFNet	0.028	3.64 %	0.980

Висновки. У роботі представлено покращену модель RouteNet шляхом впровадження можливості врахування різних характеристик вузлів, таких як розміри черг. Розширена модель продемонструвала кращі результати за метриками точності і здатності до узагальнення на нові топології. Ці результати підтверджують, що покращення моделі дозволяє більш точно враховувати реальні умови мережі і адаптуватися до різних сценаріїв.

Робота також демонструє, що RouteNet не слід розглядати як незмінну модель, а її можна адаптувати під різні потреби в інтуїтивно зрозумілій для мережі манері. Рішення не тільки демонструє хороші експериментальні результати, але також розроблено з урахуванням можливих майбутніх програм або покращень.

Подальші дослідження в областях імітаційного моделювання та оптимізації мережі з використанням RouteNet, особливо у поєднанні з методами машинного навчання, представляють собою перспективний напрям. Вони можуть включати розробку нових методів для покращення здатності моделі до узагальнення на нові топології та сценарії, а також дослідження впливу різних параметрів вузлів на продуктивність моделі.

СПИСОК ЛІТЕРАТУРИ

1. Antoshchuk S. G., Breskina A. A. “Human action analysis models in artificial intelligence based proctoring systems and dataset for them”. *Applied Aspects of Information Technology*. 2023; 6 (2): 190–200. DOI: <https://doi.org/10.15276/aait.06.2023.14>.
2. Tishin P. M., Buyukli, V. S. “The study of the quality of multi-step time series forecasting”. *Herald of Advanced Information Technology*. 2022; 5 (3): 210–219. DOI: <https://doi.org/10.15276/hait.05.2022.16>.
3. Mashtalir S. V., Nikolenko O. V. “Data preprocessing and tokenization techniques for technical Ukrainian texts”. *Applied Aspects of Information Technology*. 2023; 6 (3): 318–326. DOI: <https://doi.org/10.15276/aait.06.2023.22>.
4. Xu Zh., Tang J., Meng J., Zhang W., Wang Y., Liu C. H., Yang D. “Experience-driven networking: A deep reinforcement learning based approach”. *IEEE Conference on Computer Communications*. 2018. p. 1871–1879. DOI: <https://doi.org/10.1109/INFOCOM.2018.8485853>.
5. Mestres A., Alarcón E., Ji Y., Cabellos-Aparicio A. “Understanding the modeling of computer network delays using neural networks”. *Proceedings of the 2018 Workshop on Big Data Analytics and Machine Learning for Data Communication Networks*. 2018. p. 46–52. DOI: <https://doi.org/10.1145/3229607.3229613>.
6. Rusek K., Suárez-Varela J., Almasan P., Barlet-Ros P. and Cabellos-Aparicio A. “RouteNet: leveraging graph neural networks for network modeling and optimization in SDN”. *IEEE Journal on Selected Areas in Communications*. 2020; 38 (10): 2260–2270. DOI: <https://doi.org/10.1109/JSAC.2020.3000405>.
7. Buterez D. & Janet J., Kiddle S., Oglic D., Lio P. “Graph neural networks with adaptive readouts”. 2022. DOI: <https://doi.org/10.48550/arXiv.2211.04952>.

8. Barreto F., Wille E. C., and L. Nacamura L. Jr. “Fast emergency paths schema to overcome transient link failures in ospf routing”. *International Journal of Computer Networks & Communications*. 2012; 4 (2): 17–34. DOI: <https://doi.org/10.5121/ijcnc.2012.4202>.

9. Hei X., Zhang J., Bensaou B., Cheung C.-C. “Wavelength converter placement in least-load-routing-based optical networks using genetic algorithms”. *Journal of Optical Networking*. 2004; 3 (5): 363–378. DOI: <https://doi.org/10.1364/JON.3.000363>

10. Varga, A. “OMNeT++”. In: *Modeling and tools for network simulation*. Springer. 2010. p. 35–59. DOI: https://doi.org/10.1007/978-3-642-12331-3_3.

DOI: <https://doi.org/10.15276/ict.01.2024.04>

UDC 004.7

Enhancement of the graph neural network model for simulation modeling tasks

Viktor S. Buiukli¹⁾

PhD student, Department of Computer Intellectual Systems and Networks
ORCID: <https://orcid.org/0000-0001-7384-2290>; vktr.buyukli@gmail.com

Roman I. Naumenko¹⁾

PhD student, Department of Computer Intellectual Systems and Networks
ORCID: <https://orcid.org/0009-0003-7612-1773>; lwoodooz7@gmail.com

Petr M. Tishyn¹⁾

PhD in Physics and Mathematics, Associate Professor, Department of Computer Intellectual Systems and Networks
ORCID: <https://orcid.org/0000-0003-2506-5348>; petrmittal@gmail.com. Scopus Author ID: 57190400970

¹⁾ Odesa Polytechnic National University, 1, Shevchenko Ave. Odesa, 65044, Ukraine

ABSTRACT

In the context of the rapid growth and increasing complexity of network systems, the task of accurately modeling network parameters becomes critically important for effective management and optimization of network infrastructure. In this context, the work focuses on an extended version of the RouteNet model, which enhances modeling capabilities by incorporating network node characteristics such as queue sizes. The original RouteNet model demonstrates good results in predicting delays and packet losses under homogeneous network conditions; however, it has significant limitations when it comes to accounting for variations in node characteristics. The extension of the model involves integrating mechanisms to handle nodes with different configurations, allowing the model to better reflect real network conditions. This includes considering node parameters such as queue sizes, which can vary significantly in real networks. This enhancement makes the model more adaptive and accurate in conditions that are closer to real network scenarios. The study includes a series of experiments involving the training and performance evaluation of the new model, its comparison with the original version, and an analysis of the results obtained. An important aspect is the assessment of the significance of these results for network research, particularly for tasks related to the simulation of computer networks. This not only improves the accuracy of modeling but also provides more effective solutions for managing and optimizing contemporary network systems, which is crucial for their stable and productive operation.

Keywords: Graph neural network; RouteNet; network models; delay; packet loss; node queues; simulation modeling; machine learning