

РАДІОТЕХНІКА ТА ТЕЛЕКОМУНІКАЦІЇ

УДК 621.391

DOI <https://doi.org/10.32838/2663-5941/2021.1-1/01>**Андрущак В.С.**

Національний університет «Львівська політехніка»

Андрухів Т.В.

Львівська філія (керуючої філії Західного макрорегіону) ПАТ «Укртелеком»

Максимюк Т.А.

Національний університет «Львівська політехніка»

Бешлей М.І.

Національний університет «Львівська політехніка»

Думич С.С.

Національний університет «Львівська політехніка»

ІНТЕЛЕКТУАЛЬНЕ УПРАВЛІННЯ МАРШРУТИЗАЦІЄЮ В ОПТИЧНИХ ТРАНСПОРТНИХ МЕРЕЖАХ ІЗ ВИКОРИСТАННЯМ ГРАФОВИХ НЕЙРОННИХ МЕРЕЖ

У роботі представлено алгоритм інтелектуального управління маршрутизацією потоків в оптичних транспортних мережах із використанням графових нейронних мереж. Використання нейронних мереж для вирішення проблем у телекомунікаційних мережах зумовлює той факт, що ІТУ-Т вже публікує стандарти щодо інфраструктури, а також програмного забезпечення, такі як F.748.11 і Y.3172. Крім того, велика кількість наукових робіт представлена щодо підвищення ефективності роботи мереж від мережевого до фізичного рівня з використанням нейронних мереж. Використання графових нейронних мереж для вирішення телекомунікаційних задач зумовлює той фактор, що вхідними параметрами для тренування є характеристики самої мережі. Тобто матриця суміжностей, характеристики про вузли й ребра в певний момент часу є вхідними параметрами для тренування графових нейронних мереж. На базі цих даних можна спрогнозувати стан, у якому перебуває вузол. Такий підхід дає змогу більш гнучко підійти до процесу визначення стану вузла, оскільки вимагає не переписування програмного забезпечення, а лише адміністративної зміни параметрів нейронної мережі. Запропоновано інфраструктуру оптичної транспортної мережі з елементами тренування, зберігання й оновлення відповідних нейронних мереж. Здійснено моделювання трафіку оптичної транспортної мережі для визначення ефективності роботи розробленого алгоритму. Трафік був змодельований з урахуванням розподілу пакетів відео, голосу й даних залежно від пори доби і також бізнес чи спальних районів міста. Представлена топологія мережі являє собою подвійне кільце зі спільним телекомунікаційним хабом. Це дало змогу більш точно відтворити випадки перевантаження певних вузлів у певні моменти часу доби. Здійснено тренування графової нейронної мережі на базі змодельованого трафіку й відповідних характеристик вузла та ребер розглянутої топології мережі. Запропонований алгоритм дав змогу зменшити затримку в години пікового навантаження мережі на 18%.

Ключові слова: оптична транспортна мережа, графові нейронні мережі, штучний інтелект, інтелектуальне управління трафіком, маршрутизація, моделювання трафіку.

Постановка проблеми. Телекомунікаційні мережі зіткнулися з викликом великої кількості трафіку, які генерують різні сервіси. Загальнодоступність і низька ціна телекомунікаційних

послуг лише цьому сприяють. Отже, телекомунікаційні оператори повинні розробляти й підтримувати необхідну інфраструктуру оптичної транспортної мережі, яка є ядром, де передається

основна кількість трафіку. Власне технології та алгоритми каналного рівня є основним засобом ефективного передавання трафіку в транспортних мережах. Тому можна вважати доцільною задачу балансування трафіку в оптичній транспортній мережі з використанням площини управління.

Аналіз останніх досліджень і публікацій.

Будь-яка технологія каналного рівня стикається з типовими проблемами оптичних транспортних мереж [1–2]:

- зростання мережевого трафіку;
- збільшення швидкості передачі даних оптичного каналу;
- еволюція WDM систем;
- масштабування мереж;
- зменшення енергоспоживання мереж;
- підтримка застарілого програмного й апаратного забезпечення;
- уніфікація сервісів тощо.

Відповідно, кожна з технологій каналного рівня використовує власні або перевикористовує наявні алгоритми, адаптовані під інші технології для оптимізації роботи мережі. Проте кожна технологія каналного рівня має свої особливості, які частково описані вище. Це призводить до того, що будь-який алгоритм оптимізації використання мережевих ресурсів буде обмежений конфігурацією мережі та їх технологій. Отже, є сенс розробляти більш уніфіковані алгоритми, які б були придатні до використання різними технологіями каналного рівня оптичних транспортних мереж. Для вирішення цієї задачі можна використати алгоритми на базі нейронних мереж, які будуть більш адаптивні до зміни параметрів мережі.

Останнім часом набуває популярність використання графових нейронних мереж (Graph neural networks – GNN). Особливістю цих нейронних мереж є використання графа як матриці суміжності й дані про нього для тренування. Оскільки телекомунікаційна мережа представляється графом і відомо велику кількість мережевих параметрів, які описують вузол і канал зв'язку, то раціонально використати дані нейронної мережі для вирішення певних телекомунікаційних задач.

Використання нейронних мереж, а також засобів машинного навчання в телекомунікаціях мають низку недоліків і переваг [3–4]. Одним із найбільшим недоліком таких систем є висока ціна розробки, розгортання й тестування системи. Крім того, велика ціна помилки, якщо алгоритм із використанням нейронних мереж прийме неправильне рішення, що може призвести до неправильної роботи або повністю зупинити роботу оптичної

транспортної мережі. Проте для цієї проблеми є фактор, який суттєво сприяє її вирішенню, – кількість зібраних даних. Оптична транспортна мережа передає гігабіти інформації по оптичних каналах за одну секунду. Наприклад, обладнання Cisco NCS 4000 [5], яке як універсальна лінійна карта видає оптичний потік із сумарною швидкістю 400 Гбіт/с. Тобто за 20 секунд роботи ми отримуємо переданий сумарний потік даних 1 тбайт. Типова національна оптична транспортна мережа телекомунікаційного оператора складається з 20–30 вузлів. Отже, збір і кількість даних не є проблемою, оскільки сам об'єкт дослідження може забезпечити дані як для тренування, так і для тестування нейронних мереж.

Іншою проблемою є відсутність контролю або слабка участь людини в прийнятті певних рішень щодо роботи транспортної мережі. Тобто це може бути вузьким місцем, оскільки буде конфлікт щодо прийняття рішення між людиною і статичними алгоритмами, з одного боку, й алгоритмами на базі нейронних мереж. З іншого боку, є певний час реакції статичного алгоритму чи людини на певний випадок транспортної мережі. Припустимо, що середній розмір блоку даних OLS становить 100 кбайт. Якщо ми використовуємо обладнання Cisco NCS 4000 [5], де швидкість оптичного каналу може становити 100 Гбіт/с, то при швидкості реакції в 1 секунду відбудеться втрата 1 000 000 блоків даних.

Використання машинного навчання без учителя дає змогу відловлювати нетипові випадки, які складно вилловлювати статичними алгоритмами [6]. Тобто такі алгоритми можуть вилловити набагато більше нетипових подій у мережі й можуть приносити користь у прийнятті рішення на мікрорівні з погляду використання оптичних, часових та енергетичних ресурсів мережі.

Важливим елементом будь-якої телекомунікаційної мережі є здатність до масштабування [7–8]. Збільшення кількості вхідного навантаження, підключення нових сервісів із різними параметрами QoS, збільшення кількості потокового відео на вимогу, додаткові пікові навантаження й інші випадки можуть призводити до нештатних ситуацій, тому що статичні алгоритми чи інженери не здатні з достатньою швидкістю і якістю вирішити термінову задачу. Алгоритми машинного навчання без нагляду, такі як k-means, isolation forest, автоенкодер, здатні допомогти таблицям комутації на проміжних вузлах та агрегації трафіку на граничних вузлах, щоб мережа максимально швидко змогла б адаптуватися до внесених змін мережі.



Рис. 1. Варіанти застосування алгоритмів на базі машинного навчання і штучного інтелекту

Фактично використання алгоритмів на базі машинного навчання і штучного інтелекту можна розділити на категорії рівня передачі даних та управління. Наприклад, алгоритми на базі нейронних мереж у вузлах мережі можуть здійснювати «рекомендації» щодо комутації й агрегації трафіку. Метою роботи площини управління оптичної транспортної мережі є забезпечення необхідного QoS для відповідних сервісів. З іншого боку, ця площина володіє всією необхідною інформацією про роботу мережі, «знає» про всі параметри системи, її навантаження в поточний момент часу, а також поточну конфігурацію й архітектуру мережі. Тобто можна припустити, що оптична транспортна мережа є самодостатньою системою, оскільки «володіє» необхідною інформацією й може управляти сама собою. ITU-T називає такі мережі самооптимізованими мережами (SON), які здатні реагувати на певні події та приймати необхідні рішення без людської взаємодії для забезпечення нормальної роботи мережі.

Інститут ITU-T вже випускає певні стандарти роботи алгоритмів машинного навчання й нейронних мереж у телекомунікаційних мережах. Стандарт Y.3172 [9] описує ще одну проблему машинного навчання – шлях еволюції алгоритмів машинного навчання разом із телекомунікаційними мережами. Проте інтеграція алгоритмів машинного навчання в телекомунікаційних мере-

жах тільки набирає своїх обертів, певне вирішення цієї проблеми описано в роботі нижче. Стандарт F.748.11 [10] описує метрики й методи оцінювання для алгоритмів із використанням глибокого навчання нейронних мереж для нетелефонних сервісів.

У попередніх роботах [11] розроблено алгоритм агрегації IP пакетів у транспортні модулі на граничних вузлах із використанням нейронних мереж, що дало змогу, на відміну від статичних алгоритмів [12], відійти від чітких умов агрегації та більш динамічно управляти трафіком. Крім того, запропоновано використовувати нейронні мережі для більш інтелектуальної комутації трафіку на проміжних вузлах оптичної транспортної мережі [13]. В іншій роботі запропоновано метод логічного розділення ресурсів мережі 5G на основі комбінованої архітектури глибоких нейронних мереж [14].

Загалом алгоритми на базі нейронних мереж мають відіграти не основну роль у керуванні мережею, а лише допоміжну, де статичні алгоритми або людина не здатна справитися з достатньою швидкістю та якістю.

На основі аналізу літературних джерел можна зробити такі висновки. У роботах представлено місце використання нейронних мереж, проте не представлено, як відбувається їх взаємодія з площиною управління і площиною передачі даних.

Також не розглянуто, які параметри використовуються для тренування нейронних мереж, а також як відбувається їх збір. Відсутні кінцеві мережеві метрики, що показують реальний виграш від використання алгоритмів.

Постановка завдання. Метою роботи є зменшення мережевої затримки за рахунок балансування мережевого трафіку в час пікового навантаження.

Для досягнення мети розв'язуються такі наукові завдання:

- дослідження законів розподілу трафіку в різні частини доби з урахування житлових і бізнес районів міста;
- визначення характеристик вузлів та оптичних лінійних трактів для тренування графових нейронних мереж;
- тренування графових нейронних мереж на базі отриманих параметрів;
- балансування трафіку на базі розроблено алгоритму для зменшення затримки в години пікового навантаження.

Виклад основного матеріалу дослідження.

Інфраструктура оптичної транспортної мережі на базі технології OLS і нейронних мереж. У попередній роботі [11] представлено архітектуру оптичної транспортної мережі на базі технології OLS. На рис. 2 представлено спрощену архітектуру оптичної транспортної мережі з інфраструктурою алгоритмів машинного навчання.

Запропонована архітектура, побудована згідно з рекомендаціями ITU-T Y.3172, містить такі елементи:

SRC (source) – вузол, який є джерелом інформації для алгоритмів машинного навчання. У запропонованій архітектурі джерелом інформації є граничні та проміжні вузли, власне обладнання каналного рівня;

C (collector) – цей вузол відповідальний за збір даних з одного або більше SRC вузлів. У даному випадку цю задачу виконує SDN контролер;

PP (preprocessor) – цей вузол відповідальний за очищення, агрегацію та виконання інших операцій попередньої обробки даних. У такому випадку роль цього вузла також виконує відповідне програмне забезпечення на SDN контролері;

M (model) – безпосередньо модель машинного навчання;

P (policy) – вузол чи програмне забезпечення, яке описує політику використання вихідних даних моделей;

D (distributor) – вузол, який визначає якому SRC надати вихідну інформацію з алгоритму машинного навчання. У цій архітектурі це також SDN контролер;

SINK – вузол, що є метою для вихідних даних алгоритму машинного навчання. У запропонованій архітектурі це обладнання каналного рівня технології OLS.

Запропонована архітектура відповідає за збір даних для відповідних нейронних мереж, які вже безпосередньо будуть займатися оптимізацією роботи мережі. Запропоновано зберігати мережеві параметри Feature Engineering (FE) для тренування в окремі бази даних (у хмарі). Крім того, ще один cloud розрахований під резервне збері-




Рис. 2. Інфраструктура алгоритмів машинного навчання (HM – нейронна мережа)

гання нейронних мереж для випадків, коли необхідно повернути попередню версію. Алгоритми на базі нейронних мереж працюють як на рівні управління, як на SDN контролері, так і безпосередньо на вузлах мережі.

Математичний апарат графових нейронних мереж. Графові нейронні мережі (GNN) – це тип нейронних мереж, який безпосередньо працює зі структурою даних у вигляді графу. Такі мережі розширюють наявні нейронні мережі для обробки даних у домені типу даних графів. Ці нейронні мережі використовуються в основному для класифікації вузлів. Кожен вузол у графі асоціюється з міткою тренування, відповідно, мережа намагається на базі вхідних даних «спрогнозувати» потрібний вузол. Оскільки телекомунікаційна мережа представляється у вигляді графа для відображення логічних і фізичних зв'язків між вузлами, то цей тип нейронних мереж підходить для вирішення певних задач телекомунікаційних мереж.

Ціллю GNN є вивчення стану вузла h_v з урахуванням інформації про стан сусідніх вузлів [15]. У контексті GNN стан вузла v описується вектором даних розміру s для генерування вихідних даних o_v . Припустимо, що f є параметрична функція, яка передається через кожен вузол та оновлює стан вузла відповідно до вхідних даних. Припустимо, що g є локальною вихідною функцією, що описує генерацію вихідних даних. Відповідно, h_v та o_v визначаються так:

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

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

де x_v – характеристики вузла, $x_{co[v]}$ – характеристики ребра, $h_{ne[v]}, x_{ne[v]}$ – стан і характеристики сусідніх вузлів відповідно.

Припустимо, що $H, O, X, i X_N$ вектори, які побудовані складанням усіх станів, вихідних даних, характеристик і характеристик усіх вузлів відповідно, які можна також представити в такій формі:

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

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

де F – функція глобального переходу, G – глобальна вихідна функція, яка складається з групи функцій f і g для всіх вузлів графа відповідно.

Наступним етапом є тренування нейронних мереж, тобто навчання параметрів f і g . На базі цільової інформації (t_v для певного вузла) для навчання з наглядом, утрати можуть бути описані так:

$$l = \sum_{i=1}^p (t_i - o_i), \quad (5)$$

де p – кількість вузлів.

Проте GNN мають низку недоліків. Одним із таких недоліків є неефективне оновлення збережених станів вузла для фіксованих точок. Це може бути поправлено шляхом додавання шарів до нейронної мережі, що призводить до надлишковості. По-друге, GNN використовує ті самі параметри під час тренування, коли інші нейронні мережі використовують різні параметри в різних шарах. По-третє, деякі характеристики ребер не можуть бути ефективно промодельовані в оригінальних GNN. Проте, незважаючи на низку недоліків, GNN має місце для вирішення певного роду задач у телекомунікаційних мережах.

На базі вищеописаної інформації алгоритми з використанням GNN можна використати для таких цілей:

- оптимізації глобальної маршрутизації в транспортній мережі;
- агрегації трафіку на граничних вузлах;
- комутації трафіку на проміжних вузлах;
- зменшення енергоспоживання мережі загалом.

Перевагами нейронних мереж над звичайними статичними алгоритмами є те, що можна змінювати необхідні характеристики мережі й вузлів x_v . Тобто зміни вносяться шляхом перетренування нейронної мережі, а не внесенням змін у необхідне програмне забезпечення. Такий підхід дає більшої гнучкості при управлінні мережі, а також швидше вносить зміни в необхідне програмне забезпечення.

Алгоритм зменшення мережевого трафіку шляхом балансування мережевого навантаження в години найбільшого навантаження. У роботі проведено моделювання трафіку оптичної транспортної мережі для топології, заданої на рис. 3.

Вузли 1–3 знаходяться в спальному районі міста, 5–6 – у бізнес частині міста, 4 – проміжний вузол між двома районами. Колір вузла визначає завантаженість вузла: темніший колір визначає завантаженість поточного вузла. Передача даних по кільцях може здійснюватися у двох напрямках.

Уявімо, що вузол 1 хоче передати інформацію до вузла 3 по маршруту 1–2–3, проте в цей момент часу вузол 2 перевантажений. Є можливість побудувати альтернативний маршрут 1–4–3. Проте вузол 1 має дізнатися певним чином про завантаженість цього вузла. У представленій




Рис. 3. Досліджувана топологія оптичної транспортної мережі




Рис. 4. Завантаженість вузлів і побудова альтернативних шляхів передачі даних

архітектурі (див. рис. 2) роль площини управління здійснює SDN контролер, який, власне, має повідомити, що певний вузол є перевантажений у певний момент часу. Отже, алгоритм на базі GNN має повідомити вузли про стан інших вузлів для корекції маршрутизації.

На рис. 5 представлено алгоритм модифікації маршрутів в оптичній транспортній мережі. До SDN контролера передається інформація про стан вузла з інтервалом dt . Коли SDN контролер здійснив збір даних від усіх вузлів, він здійснює обчислення необхідних параметрів FE для нейронної мережі. Отримавши необхідні параметри, GNN нейронна мережа повертає стани вузлів мережі. Якщо стани вузлів змінилися щодо останнього вектора станів, то SDN контролер відсилає змінений вектор станів до вузлів. Вузли на базі вектора станів вузлів здійснюють корекції побудови маршрутів передачі даних.

Розподіл трафіку

Трафік у мережі має поведінку змінюється протягом дня, а також залежить від розміщення вузлів у бізнес чи житлових районів. Наприклад, у бізнес районі вдень переважають відео й голосові дзвінки, притому спостерігається висока активність передачі даних. Уночі в такому районі переважають статичний трафік від відеокamer, дзвінків охорони тощо. Спостерігаються скачки трафіку під час перезмінки, а також під час обідньої перерви (див. рис. 6а). Для спального району трафік динамічно змінюється протягом доби, проте ввечері спостерігається великий скачок відеоконтенту (див. рис. 6б).

На рис 7. представлено розподіл трафіку згідно з трьома параметрами:

- години дня;
- завантаженості оптичного лінійного тракту (далі – ОЛТ);
- середнього розміру блоку даних;



Рис. 5. Алгоритм модифікації маршрутів в оптичній транспортній мережі

Ці графіки більш наглядно представляють зміну трафіку протягом дня в різних районів міста. Варто наголосити, що не тільки максимальне завантаження ОЛТ призводить до високої завантаженості вузла. Наприклад, велика кількість блоків OLS невеликого розміру можуть призвести до більшого завантаженості вузла, ніж велика завантаженість ОЛТ при великих блоках. Крім того, висока завантаженість центрального процесора вузла призводить до більш високого енергоспоживання вузла.




Рис. 6. Розподіл трафіку по годинах для а) – спального району, б) – бізнес району




Рис. 7. Згенерований трафік оптичної транспортної мережі для а) – спального району, б) – бізнес району

Дослідження характеристик вузлів та оптичного лінійного тракту

У моделюванні для тренування GNN використано такі параметри в якості FE:

- час доби;
- завантаженість центрального процесора вузла;
- навантаження вхідного навантаження вузла;
- середній розмір блоку OLS за час dt;
- розподіл пакетів відео, голосу, даних для яких цей вузол є кінцевий;
- тощо.

Вхідні параметри GNN моделі представлено в таблиці 1. Як згадувалося вище, вхідними параметрами для кожної ітерації тренування є:

- матриця суміжностей на базі мережі, яка представлена на рис. 3;
- вектор характеристик вузла й ребер;
- вектор міток для розмічення тренуваних даних, що відповідають за відповідний стан вузла.

На базі змодельованих даних трафіку оптичної транспортної мережі точність натренованої GNN становить 0,956, що дає можливість правильно трактувати стани вузлів.

Проведено моделювання передачі даних між вузлами 1–3. У моделюванні розглядається два маршрути передачі даних 1–2–3 й 1–4–3. Між 14–19 годинами спостерігається вища затримка, ніж між 19–24 годинами. У моделі це відбувається через перенавантаження вузла 2. Запропонований алгоритм оптимізації на рис. 5 дає змогу здійснити перебудову логічних зв'язків між вузлами 1–3 і здійснити балансування трафіку через вузол 4. У результаті спостерігається зменшення затримки майже на 18% під час 14–19 годин.

Висновки. У роботі представлено алгоритм балансування навантаження на базі графових нейронних мереж. Здійснено порівняльний аналіз використання інших нейронних мереж у

Вхідні параметри тренування нейронної мережі

Параметр	Значення	Параметр	Значення
Швидкість навчання	0,01	Розмір вибірки тренування	24
Кількість епох	100	Кількість днів моделювання	30




Рис. 8. Результати тренування

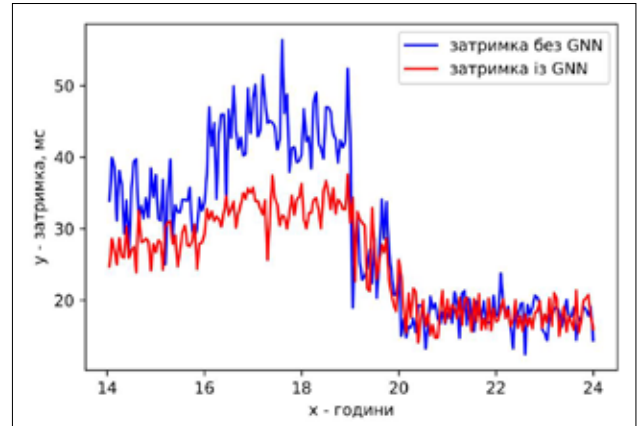


Рис. 9. Моделювання затримки маршрутів між вузлами 1–3

телекомунікаціях, а також наявність стандартів ITU-T для опису використання їх у телекомунікаційних мережах. Представлено архітектуру оптичної транспортної мережі з використанням інфраструктури нейронних мереж. У запропонованій архітектурі відображаються засоби тренування, зберігання й оновлення нейронних мереж. Здійснено моделювання трафіку оптичної транспортної мережі для топології подвійного кільця зі спільним телекомунікаційним вузлом для різних годин доби, а також спального та бізнес районів. Представлено закони розподілу трафіку для цих же районів. Представлено характеристики FE для тренування графових

нейронних мереж. Представлено результати тренування GNN у запропонованому алгоритмі оптимізації балансування трафіку. Переваги розробленого алгоритму є можливість урахувати будь-яку кількість характеристик вузлів чи оптичних лінійних трактів. Додавання чи видалення характеристик не вимагає внесення змін у програмне забезпечення, а лише перетренування й оновлення нейронної мережі. Такий спосіб більш гнучкий і більш дешевий для внесення модифікацій у площину управління мережі. Результати моделювання дало змогу зменшити затримку в години великого навантаження майже на 18%.

Список літератури:

1. Winzer P.J. Challenges and evolution of optical transport networks 36th *European Conference and Exhibition on Optical Communication*. 2010. 19–23 Sept.
2. Lucent Technologies. A practical vision for optical transport networking. URL: http://www.ece.ualberta.ca/~grover/mesh_networking/wp004%5B1%5D.pdf.
3. Makridakis S. The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. *Futures*. 2017. Vol. 90. P. 46–60.
4. Cheatham B., Javanmardian K., Samandari H. Confronting the risks of artificial intelligence. *McKinsey Quarterly*. 2019. April.
5. Cisco. Cisco NCS 4000 400 Gbps DWDM/OTN/Packet Universal Line Card Data Sheet. Link. URL: <https://www.cisco.com/c/en/us/products/collateral/optical-networking/network-convergence-system-4000-series/datasheet-c78-736495.html>.
6. An overview on application of machine learning techniques in optical networks / M. Musumeci, C. Rottondi, A. Nag, I. Masalico, D. Zibar, M. Ruffini, M. Tornatore. *IEEE Commun. Surv. Tut.* 2019. № 21 (2). P. 1383–1408.
7. Gringeri. Flexible architectures for optical transport nodes and networks / S. Gringeri, B. Basch, V. Shukla, R. Egorov, T. J. Xia. *IEEE Communications Magazine*. 2010. Vol. 48. Issue 7. July. P. 40–50.
8. Lee C., Rhee J. Efficient Design and Scalable Control for Store-and-Forward Capable. *Optical Transport Networks*. 2017. Vol. 9. Issue 8. P. 699–710.

9. ITU-T. Y.3172. Architectural framework for machine learning in future networks including IMT-2020.
10. ITU-T. F.748.11 Metrics and evaluation methods for a deep neural network processor benchmark.
11. Інтелектуальне управління інформаційними потоками в оптичних транспортних мережах / В.С. Андрущак, М.В. Кайдан, Т.А. Максимюк, С.С. Думич, Ю.В. Пиріг. *Телекомунікаційні та інформаційні технології*. 2019. № 97 (3). С. 4–16.
12. Study and Development of Next-Generation Optical Networks / Т. Maksymyuk, S. Dumych, O. Krasko, M. Kaidan and B. Strykhalyuk. *Smart Computing Review*. 2014. Vol. 4. № 6.
13. Scalability Parameter in All-Optical Switches For Optical Label Switching Network / М. Kaidan, V. Andrushchak, Т. Maksymyuk, М. Klymash. *CADSM-2019 15th International Conference on the Experience of Designing and Application of CAD Systems in Microelectronics (CADSM-2019)* (26 February – 2 March, 2019, Lviv-Svaljava, Ukraine). 2019. P. 120–123.
14. Метод адаптивного логічного розділення мережі 5G на основі глибокого навчання / Т.А. Максимюк, Б.П. Шубин, Д.О. Мисаковець, В.С. Андрущак, С.С. Думич. *Вчені записки таврійського національного університету імені В.І. Вернадського*. 2020. Том 31 (70). № 5. С. 36–41
15. F. Scarselli. The graph neural network model / F. Scarselli, М. Gori, А. Tsoi, М. Hagenbuchner, G. Monfardini. *IEEE Transactions on Neural Networks*. Vol. 20. № 1. P. 61–80. 2009.

Andrushchak V.S., Andrukhiv T.V., Maksymiuk T.A., Beshlei M.I., Dumych S.S. INTELLIGENT ROUTING MANAGEMENT IN OPTICAL TRANSPORT NETWORK USING GRAPH NEURAL NETWORK

The algorithm of intelligent flow routing control in optical transport networks with the use of graph neural networks is presented in the work. The use of neural networks to solve problems in telecommunications networks is due to the fact that ITU-T already publishes standards for infrastructure and software such as F.748.11 and Y.3172. In addition, a large number of scientific papers are presented to improve the efficiency of networks from the network to the physical level using neural networks. The use of graph neural networks to solve telecommunications problems is due to the fact that the input parameters for training are the characteristics of the network itself. That is, the matrix of adjacencies, characteristics of nodes and edges at a certain point in time are the input parameters for training graph neural networks. Based on these data, you can predict the state in which the node is. This approach allows a more flexible approach to the process of determining the state of the node because it does not require rewriting the software but only administratively changing the parameters of the neural network. The infrastructure of the optical transport network with elements of training, storage and updating of the corresponding neural networks is offered. The traffic simulation of the optical transport network is carried out to determine the efficiency of the developed algorithm. Traffic was modelled based on the distribution of video, voice and data packets depending on the time of day and also the business or sleeping areas of the city. The presented network topology is a double ring with a common telecommunication hub. This allowed us to more accurately reproduce the cases of overload of certain nodes at certain times of the day. The graph neural network is trained on the basis of the simulated traffic and the corresponding characteristics of the node and edges of the considered network topology. The proposed algorithm allowed to reduce the delay during peak hours of the network by 18%.

Key words: optical transport network, graph neural networks, artificial intelligence, intelligent traffic management, routing, traffic modelling.