

<https://doi.org/10.31891/2219-9365-2023-73-1-13>

УДК 621.391

Микола ВАСИЛЬКІВСЬКИЙ

Вінницький національний технічний університет

<https://orcid.org/0000-0002-6586-2563>

e-mail: mvasylkivskiy@gmail.com

Ольга БОЛДИРЕВА

Вінницький національний технічний університет

e-mail: rtl13bpoludenko@gmail.com

Ганна ВАРГАТЮК

Вінницький національний технічний університет

e-mail: annaantonuik@gmail.com

Михайло БУДАШ

Вінницький національний технічний університет

e-mail: mika@budash.dp.ua

КЕРУВАННЯ ТЕЛЕКОМУНІКАЦІЙНИМИ МЕРЕЖАМИ З ВИКОРИСТАННЯМ ТЕХНОЛОГІЙ AI/ML

В роботі наведено результати досліджень поточного стану і нових тенденцій застосування AI/ML при керуванні мережами та послугами. Розглянуто базові технології, які є фундаментальними для наскрізного створення ресурсів і керування ними. За допомогою таких технологій мережі 5G можуть автоматизувати обробку ресурсів і ізоляцію між логічними та фізичними ресурсами. У цьому сенсі розглянуто останні підходи в домені RAN з відкритою мережею радіодоступу (O-RAN). Також зосереджено увагу на відповідних контролерах, заснованих на стеку Європейського інституту телекомунікаційних стандартів керування та оркестровки (ETSI MANO), і, зокрема, на тому, як обробляються обчислювальні ресурси. Після чого розглядаються фундаментальні ідеї та останні тенденції програмування площини даних на рівні пакетів і на рівні оптичного перемикачів, зосереджуючись на транспорті керування мережними ресурсами. Також описано створення конвеєра даних для забезпечення стека керування мережним моніторингом і аналітикою.

Досліджено основні підходи до управління різними архітектурними компонентами мережі 5G. У ході розгляду зазначено, що різноманітність проблем на кожному архітектурному рівні, звичайно, вимагає різних підходів. Також розглянуто керування ресурсами RAN за допомогою виявлення моделей поведінки користувачів і розподілу ресурсів RAN за допомогою методів навчання з підкріпленням (RL) та Q-навчання. Проаналізовано традиційні методи оптимізації та підходи на основі штучного інтелекту для вирішення проблем оркестрування мережі, що містить будь-які обчислювальні ресурси. Наведені методи SoA для досягнення нарізки площини даних через ізоляцію співіснуючого трафіку. Також розглянуто надзвичайно важливе питання об'єднання ресурсів і методи ШІ, які використовуються для сприяння реалізації процедур об'єднання.

Розглянуто особливості застосування методів машинного навчання в мережній платформі, а також керування програмними мережами 5G на основі ML та оцінювання QoE. Після цього, наведено тематичні дослідження, які охоплюють керування QoE, розгортання VNF і керування зрізами. Визначено основні виклики, запропоновано, як їх можна вирішити та вказівки для операторів. Здійснено огляд алгоритмів ML, які використовуються для керування потужністю, планування користувачів, асоціації користувачів і розподілу спектру.

Ключові слова: технологія мережі 5G, відкрита мережа радіодоступу, штучний інтелект, машинне навчання, керування потужністю, планування користувачів, асоціація користувачів, розподілення спектру.

Mikola VASYLKIVSKYI, Olga BOLDYREVA,

Ganna VARGATYUK, Myhailo BUDASH

Vinnitsia National Technical University

MANAGEMENT OF TELECOMMUNICATION NETWORKS USING AI/ML TECHNOLOGIES

The paper presents the results of research into the current state and new trends in the use of AI/ML in the management of networks and services. The basic technologies that are fundamental for the end-to-end creation of resources and their management are considered. With the help of such technologies, 5G networks can automate resource processing and isolation between logical and physical resources. In this sense, the latest approaches in the RAN domain with an open radio access network (O-RAN) are considered. It also focuses on the relevant controllers based on the European Telecommunications Standards Institute Management and Orchestration (ETSI MANO) stack, and in particular on how the computing resources are handled. This is followed by a review of fundamental ideas and recent trends in data plane programming at the packet level and at the optical switch level, focusing on the transport of network resource management. It also describes the creation of a data pipeline to provide a management stack for net-work monitoring and analytics.

The main approaches to the management of various architectural components of the 5G network have been studied. The review notes that the diversity of problems at each architectural level naturally requires different approaches. RAN resource management by detecting user behavior patterns and RAN resource allocation using reinforcement learning (RL) and Q-learning techniques are also considered. Traditional optimization methods and approaches based on artificial intelligence for solving network orchestration problems containing any computing resources are analyzed. SoA methods for achieving slicing of the data plane through isolation of coexisting traffic are given. The extremely important issue of pooling resources and AI methods used to

facilitate the implementation of pooling procedures were also considered. The peculiarities of the application of machine learning methods in the network platform, as well as the management of 5G software networks based on ML and QoE evaluation, are considered. This is followed by case studies covering QoE management, VNF deployment, and slice management. The main challenges are identified, how they can be solved and instructions for operators are suggested. ML algorithms used for power management, user scheduling, user association, and spectrum allocation are reviewed.

Keywords: 5G network technology, open radio access network, artificial intelligence, machine learning, power management, user scheduling, user association, spectrum allocation.

Постановка проблеми у загальному вигляді

та її зв'язок із важливими науковими чи практичними завданнями

Сьогодні мережа, тобто Інтернет, стала основним інструментом для ефективно підтримки високоцінних рішень, які стосуються нашого повсякденного життя. Створений переважно для передачі даних, сьогодні ми використовуємо Інтернет для перегляду відео високої чіткості, проведення відеоконференцій, отримання інформації, участі в соціальних мережах, іграх, купівлі товарів і веденні бізнесу. Усі ці послуги з доданою вартістю вимагають підтримки найвищого рівня обслуговування мережі, де збої в обслуговуванні неприпустимі, а якість послуг має бути гарантована. В результаті численних впливів цифровізації Інтернет стає дедалі складнішим і важчим в керуванні, з мережами мобільного широкопasmового доступу, здатними з'єднати мільярди користувачів зі швидкістю сотні мегабіт на секунду, магістральними мережами, що простягаються на тисячі кілометрів з кількома терабітами на секунду, виділеними каналами та величезними центрами обробки даних, що містять сотні тисяч серверів, віртуальних машин і програм [1].

Маючи можливість збирати та обробляти великі обсяги даних, керування мережею та послугами стикається з новим стимулом до повної автоматизації, завдяки підходам машинного навчання та штучного інтелекту, які починають розгортатися в операційній діяльності проектування та експлуатації телекомунікаційних систем та мереж. Керування мережею та послугами реалізує, в основному, цикл керування, у якому дані про стан мережі збираються для подальшої централізованої або розподіленої обробки для виявлення змін з метою визначення дій, які потрібно впроваджувати, реагувати та контролювати зміни.

Аналіз досліджень та публікацій

Методи штучного інтелекту/машинного навчання (ML) мають важливий список застосувань у багатьох задачах керування мережами та послугами, охоплюючи (але не обмежуючись цим) класифікацію трафіку/сервісів і прогнозування для керування продуктивністю; вторгнення, виявлення зловмисного програмного забезпечення та атрибуція для керування безпекою; аналіз першопричини та ідентифікація/прогноз несправності для керування несправностями; і розподіл ресурсів/завдань/призначення для керування конфігурацією.

Враховуючи поточний прогрес у мережах/сервісах, штучний інтелект/ML знайшов своє місце в задачах керування продуктивністю завдяки своїй здатності навчатися на основі великих даних для прогнозування різних умов, агрегувати шаблони, визначати тригери для операцій і дій керування. Для прогнозування трафіку можуть використовуватись численні програми на основі машинного навчання: від прогнозування часових рядів [2] до нейронних мереж [3] та прихованих моделей Маркова [3] і генетичних алгоритмів [4]. Крім того, у багатьох інших завданнях керування продуктивністю використовуються методи AI/ML для керування трафіком у хмарних і мобільних периферійних обчисленнях, керування мережними ресурсами та розподілом, забезпечення якості обслуговування та контролю перевантаження. Вони використовують можливості методів AI/ML для навчання з часовими і динамічними даними [4–6]. Сучасні приклади таких розробок охоплюють Deep Neural Networks [7], Transfer Learning [8], Deep Reinforcement Learning [9] і Stream online learning [10].

Керування безпекою – це ще одна сфера керування мережами/сервісами, яка охоплює широке та раннє схвалення методів AI/ML. Виявлення мережних аномалій є яскравим прикладом, у якому застосовуються методи ML для їхньої здатності автоматично навчатися з даних і «витягувати» шаблони, які можна використовувати для своєчасної ідентифікації мережних аномалій [11]. Для цього застосовуються підходи часової кореляції [12], вейвлет-аналізу [13] та традиційного виявлення точки зміни [14] для створення моделей нормального/зловмисного трафіку, де послідовність дій у часовому вікні використовується для створення профілів за допомогою таких методів кластеризації, як самоорганізовувальні карти [15], K-середні [16] і моделі змішування Гауса [17]. Крім того, методи AI/ML були застосовані для виявлення мережних вторгнень, охоплюючи, але не обмежуючись цим, дерева рішень, еволюційні обчислення, байєсовські мережі, опорні векторні машини та віднедавна глибоке навчання та навчання з підкріпленням [18]. Неконтрольоване навчання та потокове онлайн-навчання також використовувалися для завдань безпеки [14, 15]. Інші приклади додатків штучного інтелекту/ML у безпеці – це захист рухомих цілей, виявлення внутрішніх загроз і фільтрація мережного вмісту [16].

При керуванні несправностями прогнозування та діагностиці несправностей широке використання отримали методи AI/ML: від онлайн-навчання для виявлення точки зміни до нейронних мереж та прихованих моделей Маркова та дерев прийняття рішень, а також кількох алгоритмів неконтрольованого навчання [9–13]. Крім того, інші AI/ML були подані спеціально для прогнозування несправностей, автоматизованого пом'якшення несправностей та аналізу першопричини [4–7].

Застосування методів AI/ML було повільнішим у завданнях керування конфігурацією. Однак, з впровадженням технологій NFV і SDN це змінюється [5–6]. Такі ініціативи, як Intent Based Networking [1] і Zero Touch Networking [2], широко використовують AI/ML у бездротових мережах. Іншими прикладами завдань при керуванні конфігурацією з використанням ML є керування конфігурацією послуг, балансування мережного навантаження та маршрутизація [3–8].

Формулювання цілей статті

Метою роботи є: дослідження оптимізованих технологій керування телекомунікаційними мережами радіодоступу, інформаційними послугами та мережними даними із застосуванням методів штучного інтелекту та машинного навчання, які забезпечать мінімізацію експлуатаційних витрат.

Виклад основного матеріалу

за останнє десятиліття методи штучного інтелекту/ML застосовувалися у більшій кількості для кількох завдань керування мережами та послугами [9]. Проте все ще існують проблеми, які потрібно вирішити для успішного використання таких методів у виробничих середовищах. Однією з проблем є отримання високоякісних даних для навчання та оцінювання методів ML для функцій керування мережею та послугами. Навіть незважаючи на те, що мережних/сервісних даних у реальному світі багато і вони різноманітні, здебільшого важко отримати такі дані на основі реальних даних. У свою чергу, це не лише створює труднощі для оцінювання методів AI/ML, але й виступають на перше місце проблеми щодо конфіденційності та довіри. Ще одна проблема полягає в тому, що в сучасних мережах/сервісах дані генеруються неперервно у великому обсязі та швидкості. Вони характеризуються як стаціонарною, так і нестаціонарною поведінкою; постійно розвиваються, оскільки з часом впроваджуються нові протоколи та технології. Усе це відображається в даних в одній формі як поступові зміни в поведінці користувача/системи або як раптові зміни, можливо, через несправний пристрій або атаку на відмову на обслуговування певної мережі чи служби. Це означає, що методи AI/ML вимагають враховувати цю динаміку та зміни, навчатися за вищезазначених умов, щоб забезпечити успішне впровадження.

Ще одна проблема полягає в потребі експертів-людей (від мережних інженерів до аналітиків безпеки та менеджерів мереж/сервісів) для вивчення системи та інструментів на основі AI/ML. Це вимагає прозорих методів AI/ML для залучення експертів. Це надзвичайно важливо для широкого та успішного впровадження методів AI/ML при керуванні мережами та послугами.

Нарешті, ці виклики також створюють можливості у вигляді потреби в прозорих і надійних методах на основі AI/ML для керування мережею та послугами. З цією метою здійснюється застосування потокового навчання, змагального навчання та перенесення навчання в мережу й рішення для керування послугами. Крім того, дослідження прозорих, безпечних і надійних методів AI/ML отримали значний імпульс в ML. Враховуючи масштаб і динаміку сучасних мереж/сервісів, передбачається, що застосування методів AI/ML ставатиме все більш і більш повсюдним і центральним для операцій і керування майбутніми сервісами та мережами.

Віртуалізація мереж і послуг полегшує нову бізнес-модель, а саме: мережу як послугу (NaaS), яка забезпечує поділ між додатками, послугами та мережами, які їх підтримують [16]. Оператори мереж можуть прийняти модель NaaS, щоб розділити свої фізичні мережні ресурси на кілька VN (також званих мережними зрізами) і здати їх в оренду постачальникам послуг [17].

У свою чергу, постачальники послуг використовують віртуальні мережі, щоб пропонувати послуги з різноманітними вимогами до QoS без будь-яких інвестицій у створення та управління фізичною інфраструктурою.

Ідеальним втіленням моделі NaaS є нарізка мережі для мобільних мереж п'ятого покоління (5G). Використовуючи нарізку мережі, одну фізичну мережу 5G можна розділити на кілька ізольованих логічних мереж різного розміру та структури, призначених для різних типів послуг. Ці «самодостатні» віртуальні мережі мають бути достатньо гнучкими, щоб одночасно враховувати різноманітні бізнес-випадки використання від кількох постачальників послуг у загальній мережній інфраструктурі та створюватися на вимогу (відповідно до вимог) постачальників послуг.

Переваги віртуалізованих мереж і послуг пов'язана з додатковими проблемами керування для мережних операторів. По-перше, мережний оператор має організувати VN/мережні сегменти таким чином, щоб вони могли співіснувати в одній інфраструктурі, не впливаючи один на одного. Отже, потрібно приймати розумні рішення щодо оркестровки, щоб створити VN, які задовольняють вимоги різноманітних користувачів і програм, забезпечуючи при цьому бажане використання ресурсів. Це також передбачає налаштування великої кількості віртуальних екземплярів та їхніх робочих параметрів.

Початкову оркестровку та конфігурацію потрібно адаптувати, щоб впоратися зі змінними в часі вимогами трафіку та зміною станів мережі. По-друге, доданий рівень віртуалізації вводить нові поверхні атак і збоїв у різних адміністративних і технологічних сферах. Наприклад, будь-який збій базового фізичного ресурсу може поширюватися на розміщені віртуальні ресурси, хоча обернене не завжди достовірно. Подібним чином механізм усунення та пом'якшення наслідків для однієї VN не має загрожувати роботі співіснуючих VN. Ці різноманітні виклики вимагають автоматизованого керування, яке не може задовольнитися традиційним реактивним підходом до керування людиною в циклі. Керування віртуальними мережами має бути розумним, щоб використовувати величезний обсяг оперативних даних, створених у живій мережі, і приймати автоматизовані рішення для різних операційних і управлінських дій. Таким чином, штучний інтелект (AI) і машинне навчання (ML) можуть відігравати ключові ролі для реалізації автоматизації контролю та керування для віртуальних мереж і їхніх послуг [8, 9].

Методи AI та ML широко використовувалися для вирішення мережних проблем в останні кілька десятиліть [8, 9]. Однак, коли справа доходить до керування віртуалізованою мережею, відсутність реального розгортання віртуалізованих служб перешкоджає застосуванню методів штучного інтелекту та машинного навчання. Незважаючи на це, останнім часом відбувся сплеск досліджень, спрямованих на використання ML для вирішення складних проблем у середовищі NV [15-18].

Моніторинг вимагає ідентифікації таких ключових показників ефективності (KPI), як очікувана затримка, тривоги та використання віртуалізованих мережних компонентів [6]. Вони відіграють вирішальну роль в аналітиці для полегшення автоматизованого прийняття рішень щодо керування віртуалізованими мережами та службами. Квінтесенцією є те, що використовувані методи вимірювання збирають телеметричні дані з високою точністю, мінімізуючи накладні витрати. Однак вимірювання може збільшити витрати (наприклад, споживана пропускна спроможність мережі, пам'ять комутатора через зондування та зберігання), коли велика кількість віртуалізованих мережних компонентів відстежується через регулярні проміжки часу. Це викликає потребу в адаптивних схемах вимірювання, які можуть динамічно налаштовувати швидкість моніторингу та вирішувати, що контролювати.

Такі методи ML, як регресія, можуть полегшити адаптивний моніторинг шляхом прогнозування даних телеметрії, які в іншому випадку були б виміряні. Іншим завданням є розробка механізмів своєчасного та високоточного інструментарію моніторингу KPI віртуалізованих мереж із високими вимогами до якості обслуговування, особливо для служб із наднизькою затримкою.

Прогнозне обслуговування на основі ML може забезпечити безперерйну роботу віртуалізованих мереж [9]. Це передбачає визначення майбутніх подій на основі вимірних KPI, виявлення причин погіршення продуктивності та проактивне вжиття превентивних заходів. Прикладом є визначення того, чи призведе погіршення продуктивності (наприклад, збільшення втрати пакетів, тривалий час простою) до майбутніх порушень QoS.

Також важливо визначати причини (наприклад, неправильна конфігурація, збій) зниження продуктивності у зв'язку з потенційними сигналами тривоги. Однак усвідомити це на основі величезного обсягу телеметричних даних і стохастичного характеру мережних подій є складним завданням. Для вирішення цих проблем можна досліджувати підходи на основі даних, зокрема ML. Після визначення причини погіршення продуктивності потрібно виконати робочі процеси для зменшення впливу на KPI. Виведення цих робочих процесів і оптимальне планування їх виконання з мінімальним перериванням існуючого трафіку є нетривіальним. Однак RL, здається, добре підходить для вирішення проблеми, і його потрібно дослідити, щоб знайти оптимальні робочі процеси пом'якшення.

У мобільних мережах 5G зріз E2E VN охоплює кілька сегментів мережі, кожен з яких може мати різні технологічні та фізичні обмеження. Наприклад, мережа доступу може мати обмежену пропускну спроможність і масштабованість для мінімізації витрат і енергії, тоді як базова мережа може не мати цих проблем щодо пропускної спроможності або масштабованості.

Однак базова мережа може мати вищу затримку та енергоспоживання через великі географічні відстані та складніші мережні пристрої. Подібні компроміси існують між периферійними та центральними DC щодо потужності обробки, затримки та споживання енергії. Таким чином, буде непрактично створювати сегмент мережі для пікового попиту на трафік. Отже, потрібно досліджувати алгоритми динамічного забезпечення сегментів, де рішення про оркестрування ресурсів полегшуються моделями ML для прогнозування обсягу трафіку сегментів з часовими, просторовими міркуваннями та вимогами до якості обслуговування. Таке динамічне надання зрізу буде ввімкнено за допомогою NFV, що дозволяє створювати віртуалізовані NF на вимогу, і контролери SDN, які можуть направляти трафік до щойно створених NF [10].

Навіть за прогнозованого технічного обслуговування деякі збої, такі як порізи оптоволоконна та пошкодження телекомунікаційного пристрою, неминучі. Здатність мережного провайдера швидко усунути збій має вирішальне значення для підтримки роботи мережі. Керування відмовами має три етапи: виявлення відмов, локалізацію та ідентифікацію. Мета виявлення збою полягає в тому, щоб викликати попередження після того, як стався збій. Після виявлення несправний елемент (наприклад, вузол або тракт, відповідальний за збій) потрібно локалізувати в мережі, щоб звузити коло причини збою. Навіть після локалізації може бути

складно зрозуміти точну причину збою. Наприклад, усередині вузла мережі погіршення може бути спричинене неправильною конфігурацією або несправністю. Щоб прискорити процес усунення несправностей, всі три етапи усунення несправностей мають бути автоматизовані. Цікавим напрямком дослідження є розробка моделей ML і алгоритмів для автоматичного виявлення, локалізації та ідентифікації збоїв на основі даних, згенерованих у виробничих мережах. Ці моделі зменшать середній час відновлення після подій збою, таким чином підвищуючи доступність сегмента мережі або віртуалізованої мережі/послуги.

Вимоги до трафіку та/або вимоги до QoS віртуалізованої мережі або її фрагмента можуть змінюватися з часом через зміну кількості користувачів і моделей зв'язку [6]. Отже, початковий розподіл ресурсів потрібно адаптувати до таких змін, спричиняючи при цьому мінімальні завади для існуючого трафіку. Це вимагає, щоб моделі ML передбачали зміни у вимогах своєчасно й точно, а також сприяли динамічній адаптації розподілу ресурсів.

Крім того, з часом прихід і вихід віртуалізованих мереж або мережних фрагментів може призвести до фрагментації та спотвореного використання додатків і серверів обробки. Це, у свою чергу, може вплинути на прийняття майбутніх запитів і призвести до непотрібного споживання енергії. Один із способів пом'якшити це – повторна оптимізація розподілу смуги пропускання та періодична консолідація віртуальних машин або контейнерів. Рішення також має виводити послідовність операцій (наприклад, міграція віртуальної машини, міграція віртуального каналу та перерозподіл пропускної спроможності), які приводять до стану збалансованого навантаження. RL є ідеальною технікою для створення послідовності операцій, для досягнення оптимізованого стану.

У розгортанні NFV або в сегментах мережі VNFI, які знаходяться на віртуальних машинах або контейнерах, масштабуються відповідно до вимог служби. Однак продуктивність VNF чутлива до основного апаратного забезпечення [5, 6]. Наприклад, можливості обробки трафіку віртуальних ЦП на процесорі Intel Xeon відрізняються від процесора AMD Opteron [5]. Подібним чином час завантаження для віртуальних машин відрізняється для таких різних VIM, як OpenStack, Eucalyptus і OpenNebula [13]. Тим не менш, більшість досліджень передбачає однорідне обладнання, не звертаючи уваги на його вплив на продуктивність VNF. Це надмірне спрощення, яке може призвести до неякісних моделей ML і неточних рішень щодо масштабування на практиці. Таким чином, дуже важливо розробити профілі продуктивності [16], які охоплюють чутливість продуктивності VNF на різному обладнанні. У разі горизонтального масштабування ці профілі можна використовувати для точного вимірювання впливу на продуктивність нових VNFI на різних фізичних серверах. Дійсно, задіяння цих профілів збільшить розмірність проблеми масштабування. Найпростішим варіантом є врахування апаратної чутливості як вартості. Однак створення профілів продуктивності VNF для різного обладнання є громіздким завданням. Залишається оцінити, як ці апаратні профілі продуктивності вплинуть на точність моделей ML і рішень щодо масштабування VNF.

Очевидно, відбувся сплеск застосування ML для керування віртуалізованими мережами, починаючи від розміщення та масштабування VNF до контролю доступу в сегментах мережі. Однак численні дослідження припускають, що сам ML є непереможним. Це нереалістичне припущення, оскільки зловмисники можуть спотворити навчальні дані або скомпрометувати агента RL, маніпулюючи станами та політиками системи, що призведе до неповноцінних дій [2]. Наприклад, перешкоджання фактичному споживанню ресурсів мережею може призвести до неоптимального розміщення SFC, що призведе до втрати ресурсів та/або порушень SLA. За своєю суттю моделям ML не вистачає стійкості до спроб суперництва. Змагальне навчання вирішує це занепокоєння, використовуючи ретельно розроблені змагальні (тобто тестові) зразки з незначними порушеннями регулярних вхідних даних [3, 4]. Вони можуть бути використані для впровадження надійності в моделі ML проти атак із спотворенням даних.

На рисунку 1 показано, як масштабуються інфраструктурні ресурси, призначені для сегмента електронної охорони здоров'я, після виникнення надзвичайної ситуації. Крім того, на рисунку 1 зображений інтелектуальний агент, який приймає рішення про масштабування на основі перевірки отриманого трафіку.

Інтелектуальний агент – це інструмент керування на основі програмного забезпечення, який може базуватися на штучному інтелекті/ML та покращує мережу за допомогою самокерування, що, у зображеному сценарії, збільшує ресурси сегмента eHealth для розміщення вхідного трафіку надзвичайної події [18].

Віртуалізація мережних функцій (NFV) стала ключовим засобом для реалізації нарізки мережі, дозволяючи мережним функціям і службам віртуалізувати на стандартному обладнанні замість того, щоб працювати на спеціальному обладнанні. Таким чином, NFV додає підвищену гнучкість для запуску віртуальних мережних функцій (VNF) на серверах у різних місцях. Незалежно від використовуваної технології віртуалізації [3], NFV пропонує можливість створення нових мережних служб (NS), виведення з експлуатації NS, коли вони більше не потрібні, або масштабування та міграції NS, щоб впоратися зі змінами вимог. Крім того, сегмент мережі може бути розгорнутий через визначений NFV NS і складатися з одного або кількох таких NS. Отже, агент може автоматизувати мережне забезпечення вищезгаданих сегментів.



Рис. 1. Схема керування інформаційним трафіком мережі eHealth 5G після виникнення надзвичайної ситуації

Виконання угод про рівень обслуговування (SLA) є ключовим компонентом контрактних угод між вертикалями та постачальниками послуг. Враховуючи, що попит на мобільний трафік в 2023 році зростає до 43,9 Мбіт/с, ризик вузьких місць і порушення SLA є високим, якщо не буде змінено парадигму керування мережею [17]. Безпосереднім наслідком зростання попиту на трафік є дефіцит обчислювальних і мережних ресурсів, що належать постачальникам послуг. Якщо в інфраструктурі постачальника послуг закінчуються ресурси, він може покладатися на парадигму федерації, підхід, який передбачає розподіл послуг або ресурсів між власниками інфраструктури або постачальниками послуг. Наприклад, два власники інфраструктури нададуть інтерфейси для оренди своїх ресурсів один одному, тому обидва вони зможуть негайно орендувати дисковий простір, радіопокриття в певній сфері або службу кешування місцезнаходження. Оренда відбувається під егідою узгоджених угод SLA з використанням інтерфейсів пірингової інфраструктури/постачальника послуг. Об'єднання в мережі 5G не тільки розширить постачальників послуг і власників інфраструктури за допомогою більш широкого пулу ресурсів і послуг, але також дозволить постачальникам послуг задовольнити вимоги до послуг, делегуючи розгортання одноранговим доменам.

Нарізка мережі, віртуалізація та об'єднання – три ключові концепції, які дозволять здійснювати самокерування в мережах 5G. Щоб отримати максимальну віддачу від трьох із них, потрібно зрозуміти, який стан поточної мережної технології. Мережі 5G охоплюють численні сегменти мережі (тобто доступ, метро та ядро), а також такі технології, як мобільні, фіксовані та оптичні, щоб забезпечити різні типи послуг, необхідні вертикалям 5G, разом із виконанням їхніх KPI.

У цьому контексті оптичні технології вважаються необхідними для фактичного задоволення деяких із цих вимог і потреб у послугах 5G, використовуючи величезну транспортну ємність для з'єднання розподілених хмарних обчислень і центрів зберігання (тобто периферійних і основних DC). Зокрема, оптичні технології забезпечують провідне рішення для досягнення ефективної мережної інфраструктури, що задовольняє очікувані вимоги до послуг 5G з точки зору високошвидкісного підключення з низькою затримкою, енергоефективності [9].

Транспортні оптичні ресурси (тобто оптичний спектр, передавач, приймачі тощо), що підтримують послуги 5G (наприклад, між віддаленими DC), вибираються та програмується за допомогою спеціального оптичного контролера SDN. Загалом, технологічні контролери SDN централізовано керуються об'єктом вищого рівня, який називається оркестровником мережі (ресурсів). Прикладом цього є IETF Application Based Network Orchestrator (ABNO) [10]. Як правило, він спирається на ієрархічну архітектуру керування, де батьківський контролер забезпечує всеохоплювальний контроль над пулом багатотехнологічних доменів, охоплюючи пакетну та оптичну комутації [11]. Крім того, для розгортання послуг і програм 5G, які вимагають пам'яті, обчислювальних і мережних ресурсів, оркестровник мережі (наприклад, ABNO) поводить як контролер VIM, який координується екземпляром оркестровника служби (тобто, MANO). У цій спільній оркестрації IT/хмари та мережі спеціальний елемент для керування мережним з'єднанням називається диспетчером інформації глобальної мережі (WIM).

У рамках оптичних мереж добре відомо, що традиційні мережі DWDM з фіксованою сіткою еволюціонували до так званих гнучких мереж DWDM. Це необхідно для досягнення більш ефективного

використання оптичного спектра [2], сприяючи спеціальному розподілу оптичного спектра, достатнього для потреб послуги. З цією метою гнучкі мережі DWDM використовують гнучкість, яку забезпечують трансивери зі змінною смугою пропускання (SBVT). Впровадження гнучких мереж DWDM із пристроями SBVT забезпечує ефективну транспортну інфраструктуру (наприклад, з'єднання віддалених об'єктів постійного струму) для дотримання суворих вимог до послуг 5G щодо високої пропускної спроможності та низької затримки. З цією метою оптичний SDN, що керує транспортною інфраструктурою DWDM, бере на себе вибір і налаштування всіх залучених елементів мережі, таких як оптичні комутатори, оптичний спектр каналів (тобто центральна частота та ширина слоту) і параметри SBVT кінцевої точки (наприклад, формат модуляції) під час налаштування цільових міжпостійних оптичних потоків. При цьому, контролер SDN зобов'язаний: (1) гарантувати швидкість передачі даних послуги 5G; (2) мати справу з будь-якими обмеженнями фізичної передачі даних, що накладаються оптичною технологією (наприклад, максимально досяжна швидкість передачі даних), і (3) виконувати такі внутрішні технологічні обмеження, як неперервність спектра [3]. Проблема вибору просторових і спектральних шляхів, ресурсів і параметрів SBVT зазвичай вирішується за допомогою так званих алгоритмів призначення спектра маршрутизації та модуляції (RS(M)A). В останні роки було зроблено значний внесок у алгоритми маршрутизації та призначення спектра (RSA). Повний огляд, що стосується багатьох аспектів алгоритму RSA, можна знайти в [4].

Отже, оптичний контролер SDN отримує вимоги до з'єднання від оркестровника мережі. Ці вимоги визначають пари вихідних і цільових DC, які розміщують VNF, відповідно до підсумкового VNF Forwarding Graph для цільової служби 5G, пропускної спроможності, максимальної наскрізної затримки тощо [5]. Потім ці обмеження використовуються як вхідні дані для алгоритму RSA контролера SDN. Вихідні дані алгоритму RSA визначають набір оптичних ресурсів (тобто, пройдених вузлів, каналів, спектра, параметрів SBVT), щоб задовольнити вимоги підключення. Потім ці ресурси розподіляються відповідно до відповідного інтерфейсу згідно з відповідним інтерфейсом керування між контролером SDN та агентами, що обробляють кожен мережний елемент у базовій інфраструктурі оптичної мережі.

Очікується, що мобільні мережі наступного покоління працюватимуть у дуже неоднорідних середовищах. Керування мережею таких сценаріїв із залученням різних технологій і мережних сегментів вимагає багатодоменого оркестрування.

Однак у мережах мобільного зв'язку наступного покоління термін «домен» має мати додаткове й суттєве значення, головним чином накладене вимогою задоволення різноманітних потреб різних типів користувачів. Деякі потрібні функції для складання NS або розподілу ресурсів інфраструктури можуть надаватися різними організаціями, відомими як адміністративні домени (AD), підкоряючись таким різним критеріям, як дефіцит ресурсів, проста доступність служби або можливість розгортання служби, що задовольняє різні вимоги. Залежно від того, як цей процес виконується між AD, можна розрізнити об'єднання ресурсів і служб.

Отже, об'єднання ресурсів можна визначити як процес, за допомогою якого AD-споживач вимагає управління ресурсами інфраструктури AD-постачальника для розгортання NS (або його частини). З іншого боку, об'єднання послуг – це процес, у якому споживачка AD вимагає розгортання NS у домені постачальника, тоді як домен постачальника зберігає повне керування ресурсами своєї інфраструктури. Однак ефективного керування обчислювальними ресурсами та ресурсами зберігання недостатньо для досягнення цільових KPI, необхідних для вертикалей: ресурси RAN також потрібно розумно розподіляти. Зокрема, в надцільових екосистемах RAN, передбачених для 5G (і не тільки), підходи AI/ML вимагатимуть спільних стратегій, які враховуватимуть усі типи ресурсів. Розподілене навчання, а також методи розподіленого виведення вже пропонуються для використання збільшеної можливості обробки різноманітних елементів RAN, навіть використовуючи можливості пристрою кінцевого користувача, коли це можливо. В результаті, концепції AI/ML поступово стають структурними компонентами мережі, запроваджуючи нові можливості для інтелектуального керування ресурсами RAN, профілювання користувачів і мережних пристроїв, а також методи розподілу спектру.

Окрім спільного керування ресурсами, однією з найважливіших проблем є те, що досі алгоритми AI/ML, мережні та комунікаційні протоколи розроблялися окремо. Спільне керування ресурсами RAN і розробка алгоритмів AI/ML мають мати одні з високих пріоритетів на шляху до справжньої мережної парадигми, де підходи до кодування та обробки сигналів інтегровані з інфраструктурою AI. Це буде реалізовано шляхом визначення загальних вимог та обмежень, які є результатом двох доменів; наприклад, такі спільні підходи можуть містити розгляд різних методів зменшення розмірності або кодування даних для пристроїв з обмеженими обчислювальними можливостями (таких як вузли Інтернету речей), адаптивної градієнтної агрегації для покращення стійкості або методів спільного кодування каналів і ущільнення зображень у задованих бездротових середовищах.

У цьому сенсі Альянс O-RAN визначає серію варіантів використання, які поєднують моделі ML з відкритими та віртуалізованими RAN. Приклади таких варіантів використання:

- динамічні радіоресурси безпілотних літальних апаратів (БПЛА) на основі траєкторії польоту, де управління БПЛА та розподіл радіоресурсів спільно оптимізовано;

- спільне використання RAN, де віртуалізовані (можливо, спеціально створені) екземпляри точок радіодоступу від різних операторів спільно використовують загальну обчислювальну інфраструктуру на межі хмари та/або радіочастот;

- контекстне динамічне управління хэндовером для V2X, де моделі машинного навчання допомагають у прогнозуванні та класифікації завдань для налаштування послідовностей хэндовера з деталізацією UE.

3GPP вже презентував нову функцію аналізу мережних даних (NWDAF) у Rel.16 [11], яка вказує на поступове впровадження концепцій AI/ML в архітектуру основної мережі, також з точки зору стандартизації. Наразі ця функція має обмежену функціональність і розгортається лише як частина базової мережі (5GC), щоб полегшити маніпулювання політиками операторів.

Крім того, наразі аналітика даних обмежена лише інформацією, орієнтованою на 3GPP. Взвзявши вищезазначену мережну парадигму з підтримкою штучного інтелекту як орієнтир для проектування, еволюція такої NF до розподіленого, багатодоменого, об'єднаного підходу, заснованого на навчанні, використовуючи також інформацію про ресурси з мереж, що не належать до 3GPP, може потенційно підвищити можливість III мережі в напрямку безперерйного та більш гнучкого керування ресурсами RAN на межі мережі. Крім того, виділення моделей поведінки користувачів і мережі та їх використання для прогнозованого розподілу ресурсів RAN забезпечить значні додаткові переваги для поточних підходів до керування ресурсами RAN. Однак такий механізм вимагатиме радикальних удосконалень поточної архітектури та роботи NWDAF, уможливаючи підхід до розподіленого вилучення профілів, використовуючи обчислювальну потужність крайових вузлів, охоплюючи навіть UE.

Запропонована інтеграція оцінки QoE на основі ML в архітектуру 5G проілюстрована на рисунку 2. Розглядаються три етапи. Етап 1 – збирання даних: сторонній AF передає дані про продуктивність додатків у NWDAF, збагачуючи їх базовою істинністю QoE.

Етап 2 – вибір функцій і навчання моделі: цей етап охоплює типовий конвеєр ML із навчання та тестування відповідної моделі. Зокрема, велика кількість мережних характеристик генерується шляхом статистичної обробки даних моніторингу мережі. Ці функції ранжуються відповідно до їхньої важливості з точки зору оцінки QoE 2. Навчання моделі на основі ML здійснюється з використанням підмножини важливих функцій 3 і базових значень QoE, що зумовлює можливість отримати оцінки QoE 4. Далі оцінюється продуктивність моделі 5. Цей процес можна повторювати для різних наборів функцій і різних моделей 6, доки не буде отримано бажану точність оцінки [7].

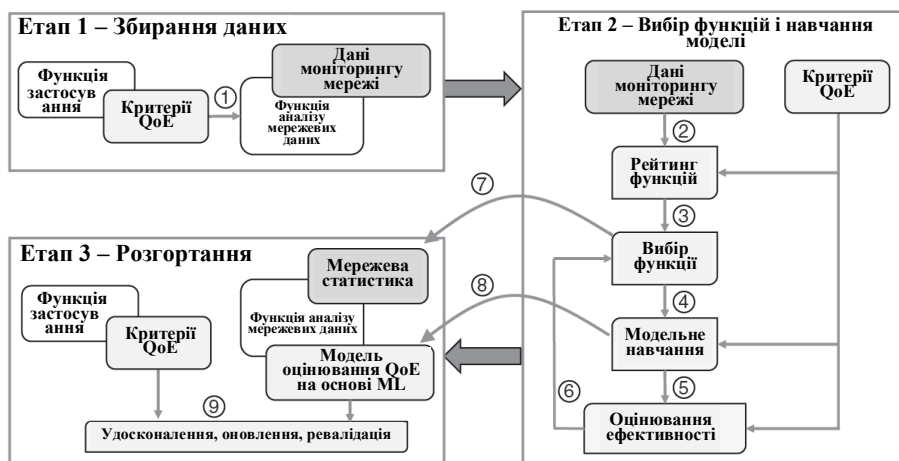


Рис. 2. Структура методу інтеграції машинного навчання в 5G

Виявлений набір функцій визначає необхідну мережну статистику, яку NWDAF має надати 7 для надійного оцінювання QoE на етапі розгортання на основі навченої моделі 8. Етап 3 – розгортання: хоча MNO тепер може оцінити QoE без потреби в метриках додатків, наданих AF, CP все ще може передавати таку інформацію для полегшення оновлень, перевірки та вдосконалення навченої моделі 9.

За допомогою цієї процедури можна вирішити проблему щодо того, як інтегрувати оцінку QoE на основі ML в архітектуру 5G. Щоб оцінити відповідні функції та врахувати компроміс між точністю та вартістю з точки зору використовуваних функцій, застосовується підхід ML LASSO до даних, отриманих із моделювання за допомогою симулятора мережі дискретних подій OMNeT++ [14]. LASSO – це метод регресійного аналізу, який виконує вибір ознак і навчає модель передбачати результат на основі вибраних ознак [15]. Його параметр регуляризації дозволяє налаштувати кількість коефіцієнтів регресії, що зменшує кількість ознак. Для будь-якого розміру набору функцій він вибирає найбільш відповідні функції з усіх

доступних. Таким чином, LASSO є відповідним способом дослідження впливу збільшення кількості ознак на точність оцінювання.

Досліджено сценарій використання потокового відео та змоделивали клієнтів у мобільній комірці з різними характеристиками руху. Релевантна для мережі інформація відстежується як часові ряди в симуляторі OMNeT++: TP UE, TP базової станції, CQI та час проходження в обидві сторони (RTT). З цих часових рядів отримуємо характеристики, застосовуючи такі типові статистичні дані, як середнє значення, стандартне відхилення, мінімум і максимум. Крім того, збираємо всі пов'язані з QoE такі показники потокового відео, як зупинки відео та якість, щоб обчислити QoE користувача за допомогою стандартизованої моделі ITU-T P.1203 [13]. Застосування LASSO до цих даних і використання різних значень параметра регуляризації дозволяє отримати набори ознак різного розміру [16].

Оцінюючи QoE за шкалою MOS на основі 33 різних пов'язаних з мережею функцій, LASSO здатний досягти середньоквадратичної помилки (MSE) приблизно 0,15.

Враховуючи той факт, що MOS коливається від 1 до 5, LASSO може досягти високої точності, незважаючи на те, що це базовий метод регресії. Загалом можна спостерігати тенденцію підвищення точності зі збільшенням розміру набору функцій. Ці висновки можуть бути корисними для оператора мережі, щоб визначити, які точки моніторингу є вирішальними та що має бути пріоритетним у плані оброблення даних. У таблиці 1 показано MSE, якого можна досягти, розглядаючи додаткові точки моніторингу для генерування характеристик. Наприклад, ми отримуємо MSE приблизно 0,32, якщо використовуються лише функції, згенеровані з TP низхідної лінії зв'язку (DL) UE. Маючи додаткові функції, які генеруються з CQI висхідної лінії зв'язку (UL), MSE падає нижче 0,25. Якщо також взяти до уваги функції, пов'язані з DL CQI, MSE можна зменшити приблизно до 0,21. Однак можна досягти лише незначного підвищення продуктивності шляхом додаткового задіяння функцій, пов'язаних із TP або RTT вузла доступу (AN).

Таблиця 1

Вплив використання різних типів моніторингу на точність QoE

Тип моніторингу	UE DL TP	CQI UL	CQI DL	UE UL TP	AN UL TP	RTT	AN DL TP
Значення MSE	0,318	0,236	0,215	0,193	0,189	0,153	0,151

При цьому, не тільки вивчалась релевантність самої функції, але й додатково оцінювали, чи впливають характеристики руху клієнтів на процес оцінювання QoE.

Дійсно, можна помітити, що мобільність має значний вплив на QoE і, як наслідок, на функції, вибрані LASSO. Функції для статичних клієнтів здебільшого генеруються на основі таких статистичних даних, як середнє значення, медіана або різні проценти. Однак для клієнтів, які переміщуються, більшість функцій генерується на основі статистики, яка виражає дисперсію. Наприклад, стандартне відхилення, коваріація або асиметрія. Як наслідок, оператор MNO має проводити моніторинг із більшою деталізацією, якщо він націлений на надійне оцінювання QoE для мобільних клієнтів. В іншому випадку варіації часових рядів, наприклад у CQI або DL TP, не може бути зафіксовано достатньо точно. Як наслідок, витрати на оцінювання QoE вищі в мобільних сценаріях [5].

Парадигми програмного забезпечення, такі як SDN і NFV, надають мережним операторам переваги щодо гнучкості, масштабованості та ефективності витрат. Крім того, вони є ключовими факторами для концепції SFC, яка дозволяє пов'язувати різні NF для формування ланцюжків послуг, а також динамічно змінювати їх структуру та розмір для адаптації до мережних подій. Оскільки сучасні комунікаційні мережі мають підтримувати численні різноманітні служби, які працюють на одному фізичному субстраті та вимоги до яких динамічно змінюються протягом усього терміну служби, ефективно управління та робота цих мереж вимагає високого рівня автоматизації в поєднанні з проактивним прийняттям рішень. Це гарантує підтримку ефективності використання ресурсів без впливу на якість обслуговування.

Особливо важливим кроком є визначення оптимальної кількості екземплярів VNF для задоволення поточних і майбутніх запитів на обслуговування. Це безпосередньо впливає на ефективність використання ресурсів і є основою для наступних рішень, таких як розміщення та з'єднання VNF.

Протягом останніх років методи RL довели свою потенційну застосовність до питань розподілу ресурсів. Однак результативність методів RL глибоко взаємопов'язана з тим, як налаштовано середовище та система винагороди. Залежно від припущень, зроблених у системі, методи RL можуть дати абсолютно різні результати. Наскільки нам відомо, методи RL ще не застосовувалися для розподілу SFC, де передбачалися інфраструктури туманно-хмарних технологій і контейнерні служби. Крім того, динамічна поведінка мережі та різні стратегії планування (наприклад, низька затримка, енергоефективність) не були повністю розглянуті. Проте методи RL довели, що навчання безпосередньо з досвіду може працювати на практиці та запропонувати справжню альтернативу підходам, заснованим на евристичних дослідженнях. Таким чином, пропонується новий підхід RL для розподілу SFC у FC. Потрібно зазначити, що для розробки підходу RL

розглядалися лише хмарні формулювання, а бездротові аспекти, доступні в моделі, не використовувалися.

Для цієї роботи сформульовано нову мету для моделі MILP: мінімізація загальної вартості системи, що перетворюється на підвищення енергоефективності. Використовуючи номенклатуру складу MILP, наведену в таблиці 2, цю мету можна виразити, як показано в рівнянні (1). Агент намагатиметься дізнатися, як мінімізувати загальну вартість системи, оскільки формула MILP взаємодіє з середовищем спортивного туману [11].

$$\sum_{a \in A} \sum_{id \in ID} \sum_{s \in S} \sum_{\beta_i \in \beta} \sum_{n \in N} p_{s, \beta_i}^{a, id}(n) \times \varpi_n \times \omega_s \times \gamma_s \times \delta_s \quad (1)$$

Таблиця 2

Змінні, що використовуються для мінімізації загальної вартості системи

Символ	Опис
$p_{s, \beta_i}^{a, id}(n)$	Матриця розміщення, якщо $p_{s, \beta_i}^{a, id}(n) = 1$, репліка β_i мікросервісу S виконується на вузлі n для програми a з ідентифікатором SFC id
ϖ_n	Відповідна вага для вузла n
ω_s	Вимога до ЦП (у ЦП) мікросервісу S
γ_s	Вимога до пам'яті (у ГБ) мікросервісу S
δ_s	Вимога до пропускної спроможності (у Мбіт/с) мікросервісу S

Простір спостереження відповідає стану, що подає середовище на даному кроці.

Результати довели, що запропонований агент може отримати продуктивність, порівнянну з найсучаснішими формулами ILP для статичних випадків використання, де 100% запитів було прийнято з загальними витратами на 5% нижчими, ніж модель MILP. Навпаки, динамічні сценарії використання також довели свою складність, показавши, що практичних рішень, здатних зменшити загальну вартість і прийняти всі запити користувачів, досі немає. Агент може знизити витрати до 50% і прийняти в середньому 60% запитів. Розробка систем RL, здатних навчатися безпосередньо на досвіді без будь-яких попередніх знань і здатних перерозподіляти послуги в інфраструктурі, реагуючи на раптові зміни мережі, стане наступною головною темою в цій галузі досліджень.

Методи RL вже довели свою потенційну застосовність до домену надання ресурсів. Однак продуктивність цих методів глибоко взаємопов'язана зі способом налаштування системи RL. Середовище є ключем до проблеми. Взаємодія між агентом і середовищем сильно впливає на продуктивність цих алгоритмів [12]. Крім того, стан і простір дій проблеми можуть зростати експоненціально залежно від розміру інфраструктури (тобто кількості вузлів, кількості служб), яка використовується в середовищі, що може призвести до нерозв'язної проблеми. Нарешті, не потрібно нехтувати важливістю системи винагород. Агент навчиться правильно розподіляти послуги, лише якщо він буде компенсований позитивними винагородами в процесі навчання, навіть якщо він не зміг досягти бажаних рішень. Головне – давати агенту вищі винагороди, чим коли він ближче до досягнення кінцевої мети, інакше агенту буде досить складно навчитися правильних дій. Навпаки, методи на основі ILP важко реалізувати на практиці через час їх вирішення. Крім того, вони вимагають багато початкової інформації, яка надходить в алгоритм, щоб можна було знайти оптимальні схеми розподілу [13]. Ці методи можуть зайняти години або навіть дні, щоб знайти оптимальний розподіл послуг, і коли відбуваються зміни в мережі, перерозподіл послуг має бути зроблений якомога швидше. Іншою проблемою є відсутність досвіду як у сферах RL, так і в сфері розподілу ресурсів. Невелика кількість експертів мають фундаментальні знання в обох сферах, що ускладнює реалізацію рішень RL, адаптованих до проблем розподілу ресурсів. Більшість методів RL, які використовуються в мережах, була створена для інших типів програм (наприклад, видеоігор).

Висновки з даного дослідження і перспективи подальших розвідок у даному напрямі

Розглянуто проблеми, з якими стикаються розробники систем 5G, що відповідають KPI, необхідних для мобільних послуг наступного покоління. Зокрема, дослідження зосереджено на таких аспектах, як мережі радіодоступу, оптичні мережі, керування площиною даних, нарізка мережі та оркестрування послуг, і також розглянуто найвідоміші рішення, існуючі в науковій літературі, а також ті, що пропонуються відповідними організаціями з розробки стандартів. При цьому виділено два основні підходи, які знадобляться для розробки систем 5G і не тільки: автономне керування мережею на основі даних і об'єднання різних AD.

Досліджено нові напрямки, які мають високий потенціал щодо підвищення ефективності й способи підходу до них за допомогою методів на основі машинного навчання, які інтегрують і розширюють існуючі механізми проектування. Зокрема, зосереджено увагу на визначенні відповідних рівнів деталізації для диференціації послуг і розробки стратегій управління зрізами з урахуванням сервісів, спрямованих на оптимальне відображення та спільне використання ресурсів.

Підводячи підсумок, у сфері розподілу ресурсів залишається кілька проблем. Тим не менш, враховуючи динамічну поведінку мережі та потребу в ефективних стратегіях планування (наприклад, енергоефективність, низька затримка), методи RL довели, що за достатнього навчання вони можуть бути адекватним рішенням для забезпечення ресурсами в туманно-хмарних інфраструктурах. Крім того, ці методи продемонстрували свій потенціал у практичних сценаріях, де поточні рішення на основі ІЛР мають кілька недоліків, особливо з точки зору масштабованості. Розглянутий високий рівень автоматизації проектування в поєднанні з проактивним прийняттям рішень забезпечить ефективне керування та експлуатацію сучасних комунікаційних мереж, які мають підтримувати численні різномірні служби, які працюють на одному фізичному субстраті та вимоги до яких динамічно змінюються протягом усього терміну служби. Це гарантує підтримку ефективності використання ресурсів без впливу на якість обслуговування.

Література

1. Hardegen, C., Pfühl, B., Rieger, S., and Gepperth, A. (2020). Predicting network flow characteristics using deep learning and real-world network traffic. *IEEE Transactions on Network and Service Management* 17 (4): 2662–2676.
2. Khatouni, A.S., Seddigh, N., Nandy, B., and Zincir-Heywood, N. (2021). Machine learning based classification accuracy of encrypted service channels: analysis of various factors. *Journal of Network and Systems Management* 29 (1): 1–27.
3. Bag, T., Garg, S., Rojas, D.F.P., and Mitschele-Thiel, A. (2020). Machine learning-based recommender systems to achieve self-coordination between son functions. *IEEE Transactions on Network and Service Management* 17 (4): 2131–2144. <https://doi.org/10.1109/TNSM.2020.3024895>.
4. Renga, D., Apiletti, D., Giordano, D. et al. (2020). Data-driven exploratory models of an electric distribution network for fault prediction and diagnosis. *Computing* 102 (5): 1199–1211. <https://doi.org/10.1007/s00607-019-00781-w>.
5. Park, S., Kim, H., Hong, J. et al. (2020). Machine learning-based optimal VNF deployment. 21st Asia-Pacific Network Operations and Management Symposium, APNOMS 2020, Daegu, South Korea (22–25 September 2020), IEEE, pp. 67–72. <https://doi.org/10.23919/APNOMS50412.2020.9236970>.
6. Zhang, Q., Wang, X., Lv, J., and Huang, M. (2020). Intelligent content-aware traffic engineering for SDN: an Ai-driven approach. *IEEE Network* 34 (3): 186–193. <https://doi.org/10.1109/MNET.001.1900340>.
7. Alam, I., Sharif, K., Li, F. et al. (2020). A survey of network virtualization techniques for internet of things using SDN and NFV. *ACM Computing Surveys (CSUR)* 53 (2): 1–40.
8. Rodriguez, V.Q., Guillemin, F., and Boubendir, A. (2020). 5G E2E network slicing management with ONAP. *Conference on Innovation in Clouds, Internet and Networks and Workshops (ICIN)*, IEEE, pp. 87–94.
9. Yan, Z., Ge, J., Wu, Y. et al. (2020). Automatic virtual network embedding: a deep reinforcement learning approach with graph convolutional networks. *IEEE Journal on Selected Areas in Communications* 38 (6): 1040–1057.
10. Abiko, Y., Saito, T., Ikeda, D. et al. (2020). Flexible resource block allocation to multiple slices for radio access network slicing using deep reinforcement learning. *IEEE Access* 8: 68183–68198.
11. Pei, J., Hong, P., Pan, M. et al. (2020). Optimal VNF placement via deep reinforcement learning in SDN/NFV-enabled networks. *IEEE Journal on Selected Areas in Communications* 38 (2): 263–278.
12. Schwarzmann, S., Marquezan, C.C., Trivisonno, R. et al. (2020). Accuracy vs. cost trade-off for machine learning based QoE estimation in 5G networks. *IEEE International Conference on Communications: Next-Generation Networking and Internet Symposium (IEEE ICC NGNI Symposium)*, Dublin, Ireland, June 2020, pp. 1–6.
13. Ibrahim, H., Tabassum, H., and Nguyen, U.T. (2020). The meta distributions of the SIR/SNR and data rate in coexisting Sub-6GHz and millimeter-wave cellular networks. *IEEE Open Journal of the Communications Society* 1: 1213–1229.
14. Hussain, F., Hussain, R., Hassan, S., and Hossain, E. (2020). Machine learning for resource management in cellular and IoT networks: potentials, current solutions and open challenges. *IEEE Communication Surveys and Tutorials* 22 1–26.
15. Shafin, R., Liu, L., Chandrasekhar, V. et al. (2020). Artificial intelligence-enabled cellular networks: a critical path to beyond-5G and 6G. *IEEE Wireless Communications* 27 (2): 212–217.
16. Bengio, Y., Lodi, A., and Prouvost, A. (2021). Machine learning for combinatorial optimization: a methodological tour d’horizon. *European Journal of Operational Research* 290 (2): 405–421.

17. Васильківський, М., Нікітович, Д., & Болдирева, О. (2022). Керування доступом до інформаційних даних в інтелектуальних інфокомунікаційних мережах. *Measuring and computing devices in technological processes*, (4), 5–17. <https://doi.org/10.31891/2219-9365-2022-72-4-1>

18. Васильківський, М., Варгатюк, Г., & Болдирева, О. (2022). Дослідження архітектури штучного інтелекту для інфокомунікаційних мереж 6G. *Measuring and computing devices in technological processes*, (4), 62–70. <https://doi.org/10.31891/2219-9365-2022-72-4-7>

References

1. Hardegen, C., Pfülb, B., Rieger, S., and Gepperth, A. (2020). Predicting network flow characteristics using deep learning and real-world network traffic. *IEEE Transactions on Network and Service Management* 17 (4): 2662–2676.
2. Khatouni, A.S., Seddigh, N., Nandy, B., and Zincir-Heywood, N. (2021). Machine learning based classification accuracy of encrypted service channels: analysis of various factors. *Journal of Network and Systems Management* 29 (1): 1–27.
3. Bag, T., Garg, S., Rojas, D.F.P., and Mitschele-Thiel, A. (2020). Machine learning-based recommender systems to achieve self-coordination between son functions. *IEEE Transactions on Network and Service Management* 17 (4): 2131–2144. <https://doi.org/10.1109/TNSM.2020.3024895>.
4. Renga, D., Apiletti, D., Giordano, D. et al. (2020). Data-driven exploratory models of an electric distribution network for fault prediction and diagnosis. *Computing* 102 (5): 1199–1211. <https://doi.org/10.1007/s00607-019-00781-w>.
5. Park, S., Kim, H., Hong, J. et al. (2020). Machine learning-based optimal VNF deployment. 21st Asia-Pacific Network Operations and Management Symposium, APNOMS 2020, Daegu, South Korea (22–25 September 2020), IEEE, pp. 67–72. <https://doi.org/10.23919/APNOMS50412.2020.9236970>.
6. Zhang, Q., Wang, X., Lv, J., and Huang, M. (2020). Intelligent content-aware traffic engineering for SDN: an Ai-driven approach. *IEEE Network* 34 (3): 186–193. <https://doi.org/10.1109/MNET.001.1900340>.
7. Alam, I., Sharif, K., Li, F. et al. (2020). A survey of network virtualization techniques for internet of things using SDN and NFV. *ACM Computing Surveys (CSUR)* 53 (2): 1–40.
8. Rodriguez, V.Q., Guillemin, F., and Boubendir, A. (2020). 5G E2E network slicing management with ONAP. *Conference on Innovation in Clouds, Internet and Networks and Workshops (ICIN)*, IEEE, pp. 87–94.
9. Yan, Z., Ge, J., Wu, Y. et al. (2020). Automatic virtual network embedding: a deep reinforcement learning approach with graph convolutional networks. *IEEE Journal on Selected Areas in Communications* 38 (6): 1040–1057.
10. Abiko, Y., Saito, T., Ikeda, D. et al. (2020). Flexible resource block allocation to multiple slices for radio access network slicing using deep reinforcement learning. *IEEE Access* 8: 68183–68198.
11. Pei, J., Hong, P., Pan, M. et al. (2020). Optimal VNF placement via deep reinforcement learning in SDN/NFV-enabled networks. *IEEE Journal on Selected Areas in Communications* 38 (2): 263–278.
12. Schwarzmann, S., Marquezan, C.C., Trivisonno, R. et al. (2020). Accuracy vs. cost trade-off for machine learning based QoE estimation in 5G networks. *IEEE International Conference on Communications: Next-Generation Networking and Internet Symposium (IEEE ICC NGNI Symposium)*, Dublin, Ireland, June 2020, pp. 1–6.
13. Ibrahim, H., Tabassum, H., and Nguyen, U.T. (2020). The meta distributions of the SIR/SNR and data rate in coexisting Sub-6GHz and millimeter-wave cellular networks. *IEEE Open Journal of the Communications Society* 1: 1213–1229.
14. Hussain, F., Hussain, R., Hassan, S., and Hossain, E. (2020). Machine learning for resource management in cellular and IoT networks: potentials, current solutions and open challenges. *IEEE Communication Surveys and Tutorials* 22 1–26.
15. Shafin, R., Liu, L., Chandrasekhar, V. et al. (2020). Artificial intelligence-enabled cellular networks: a critical path to beyond-5G and 6G. *IEEE Wireless Communications* 27 (2): 212–217.
16. Bengio, Y., Lodi, A., and Prouvost, A. (2021). Machine learning for combinatorial optimization: a methodological tour d’horizon. *European Journal of Operational Research* 290 (2): 405–421.
17. Васильківський, М., Нікітович, Д., & Болдирева, О. (2022). Керування доступом до інформаційних даних в інтелектуальних інфокомунікаційних мережах. *Measuring and computing devices in technological processes*, (4), 5–17. <https://doi.org/10.31891/2219-9365-2022-72-4-1>
18. Васильківський, М., Варгатюк, Г., & Болдирева, О. (2022). Дослідження архітектури штучного інтелекту для інфокомунікаційних мереж 6G. *Measuring and computing devices in technological processes*, (4), 62–70. <https://doi.org/10.31891/2219-9365-2022-72-4-7>