

## **АНАЛІЗ АЛГОРИТМІВ ДИНАМІЧНОГО КЕРУВАННЯ РЕСУРСАМИ МЕРЕЖЕВИХ СЛАЙСІВ**

**Храбан Д.А., Скулиш М.А.**

*Навчально-науковий інститут телекомунікаційних  
систем, КПІ ім. Ігоря Сікорського*

*E-mail: adamthebest2015@gmail.com, mskulysh@gmail.com*

### **ANALYSIS OF ALGORITHMS FOR DYNAMIC RESOURCE MANAGEMENT OF NETWORK SLICES**

In this study, we propose a reinforcement learning (RL)-based framework for dynamic resource allocation in end-to-end network slicing with heterogeneous requirements within multi-layer MEC environments. We first outline a hierarchical multi-access edge computing (MEC) architecture and formulate a resource allocation problem for end-to-end network slicing as an optimization task using the Markov decision process (MDP). Subsequently, leveraging proximal policy optimization (PPO), we develop both independently-collaborative and jointly-collaborative dynamic resource allocation algorithms to maximize resource efficiency while ensuring QoS for slices.

Швидке поширення мобільних послуг і зростання Інтернету речей та інтелектуальних пристроїв у останні роки поставили перед мережами 5G значні виклики. Цей збільшений обсяг трафіку, спричинений розвитком мобільних додатків, таких як доповнена реальність і потокове передавання 3D-відео, потребує від мереж 5G підтримки різних випадків використання, включаючи чутливі до затримки критично важливі послуги, такі як кіберфізичні системи та програми для автономного водіння. Гнучка мережева архітектура стає невід'ємною для вирішення різноманітних вимог до ресурсів та розгортання різних послуг, тому мережевий слайсінг стає ключовою технологією для задоволення цих потреб. Індивідуальне керування ресурсами у мережах доступу та базових мережах може призвести до неоптимальної продуктивності, що підкреслює важливість структури наскрізного мережевого слайсінгу, яка об'єднує ресурси на всіх рівнях.

Включення периферійних обчислень із множинним доступом (MEC) у мережі 5G наближає обчислювальні можливості до мобільних пристроїв, покращуючи показники щодо затримки, розвантажуючи робоче навантаження на найближчі сервери. Очікується, що поєднання MEC із мережевим слайсінгом оптимізує мережеві операції та надання послуг, задовольняючи різноманітні вимоги до послуг. Незважаючи на ці потенційні переваги, дослідження динамічного управління ресурсами для наскрізного мережевого слайсінгу на основі MEC у середовищах 5G все ще тільки починаються.

Навчання з підкріпленням (RL) стало цінним підходом для вирішення проблем управління мережевим слайсінгом в мережах 5G. RL дозволяє агенту побудувати оптимальну політику взаємодії з його середовищем, можливість, особливо покращена за допомогою методів глибокого навчання, таких як глибокі Q-мережі. Конкуренція за ресурси між слайсами з різноманітними характеристиками трафіку та вимогами до

якості обслуговування (QoS) підкреслює необхідність узгоджених стратегій розподілу ресурсів для підвищення продуктивності всієї мережі.

Запропонований підхід полягає у проектуванні ієрархічної архітектури для оцінки наскрізної затримки та ефективності використання ресурсів на основі характеристик слайсу. Затримка обслуговування, що включає затримку обробки та затримку передачі, розглядається як комплексний показник для оцінки наскрізної продуктивності. Для впровадження динамічного розподілу ресурсів розроблено кілька алгоритмів на основі Proximal Policy Optimization (PPO) з метою максимізації ефективності використання ресурсів, одночасно враховуючи різноманітні характеристики мережевих слайсів. Ці алгоритми працюють у рамках децентралізованого виконання, коли кожен алгоритм використовує підходи розподіленого та централізованого навчання відповідно. Оцінки продуктивності, проведені в типовому середовищі МЕС, проливають світло на неявний зв'язок між станом і дією, демонструючи ефективність запропонованих алгоритмів у покращенні ресурсоефективності та якості обслуговування.

Архітектура наскрізної системи мережевого слайсінгу будується як ієрархічна структура, що складається з кількох вузлів МЕС, кожен із яких має власні обчислювальні та комутаційні можливості. Вузли організовані в топології дерева, з шарами, позначеними як  $L$ , і вузлами МЕС, позначеними як  $m$ . Шари простягаються від основних вузлів до листових вузлів, з однаковим розміром на всіх шарах. Мережа складається з різних слайсів, позначених як  $n$ , пристосованих до різних типів трафіку користувачів і характеризується конкретними вимогами до продуктивності, такими як допустима затримка, швидкість передачі даних і робоче навантаження. Параметри, включаючи вимоги до затримки ( $d^n$ ), швидкості надходження ( $\lambda^n$ ) і довжини потоку ( $\mu^n$ ), визначаються для кожного слайсу, щоб кількісно визначити його показники продуктивності.

Інфраструктура мережевого слайсінгу описана з наголосом на створенні слайсів для обслуговування різноманітних типів послуг на основі вимог користувачів. Кожен слайс пов'язаний із певними показниками продуктивності, включаючи допустиму затримку та швидкість передачі даних, що визначається такими параметрами, як швидкість надходження потоку та довжина. Крім того, зрізи характеризуються щільністю обробки ( $\omega^n$ ) і вимогами до ЦП ( $w^n(t)$ ), причому остання розраховується на основі швидкості передачі даних і вимог до ресурсів обробки. Модель забезпечує всебічну структуру для аналізу робочого навантаження та потреб у ресурсах різних слайсів з часом, сприяючи динамічному розподілу ресурсів на основі мінливих умов мережі та вимог користувачів.

Модель системи служить основою для подальшої розробки та оцінки алгоритмів розподілу ресурсів. Визначаючи мережеву архітектуру, характеристики слайсу та показники продуктивності, модель дозволяє оцінити використання ресурсів і QoS у наскрізній інфраструктурі мережевого слайсінгу. Ця детальна характеристика мережевих компонентів і параметрів слайсів інформує про проектування та впровадження стратегій динамічного розподілу ресурсів, спрямованих на максимізацію ефективності використання ресурсів і задоволення вимог QoS для різноманітних типів послуг у багаторівневих середовищах МЕС.

Розподіл ресурсів передбачає визначення пропорції робочого навантаження та

трафіку, що проходить через вузли МЕС, на основі виділених ресурсів і оцінки робочого навантаження. Система прагне задовольнити вимоги до затримки для кожного слайсу, враховуючи затримки обробки та передачі. Порушення QoS виникають, коли затримки перевищують попередньо визначені порогові значення, підкреслюючи важливість ефективного розподілу ресурсів для задоволення різноманітних вимог до слайсів і забезпечення своєчасного надання послуг.

Основна мета полягає в оптимізації розподілу ресурсів для мінімізації затримок і максимального задоволення QoS між слайсами мережі. Замість того, щоб мінімізувати затримку, увага зосереджена на адаптивному розподілі ресурсів між рівнями МЕС, щоб збалансувати ефективність використання ресурсів і якість обслуговування. Цей підхід має на меті забезпечити ефективний розподіл робочого навантаження та своєчасне надання послуг у багаторівневих середовищах МЕС.

У сфері розподілу ресурсів для кількох слайсів мережі централізований підхід із суперагентом, здатним повністю спостерігати за станом системи та приймати рішення для всіх слайсів, може бути ідеальним з точки зору продуктивності. Однак така стратегія часто є непрактичною через великі витрати на оповіщення, які вона несе, особливо зі збільшенням кількості слайсів. Отже, децентралізовані підходи стають більш сприятливими. У роботі прийнято два децентралізовані методи, засновані на алгоритмі Proximal Policy Optimization (PPO), що пропонує більш практичне та масштабоване рішення. PPO оптимізує обрізану сурогатну цільову функцію, штрафує великі зміни політики та забезпечуючи стабільні оновлення політики.

Proximal Policy Optimization - це алгоритм навчання з підкріпленням, який прагне максимізувати накопичені винагороди шляхом ітеративного оновлення параметрів політики на основі спостережуваних станів і дій. Сурогатна цільова функція в PPO призначена для запобігання надмірно великих оновлень політики шляхом обрізання коефіцієнта ймовірності політики, таким чином забезпечуючи стабільні та надійні оновлення політики.

Структура розподілу ресурсів на основі PPO передбачає ітераційне оновлення параметрів політики та критичних оцінок, щоб максимізувати загальну функцію винагороди в усіх слайсах мережі. Цей підхід містить параметр відсікання для контролю величини оновлень політики, підвищуючи стабільність і надійність оптимізації політики. Збалансовуючи ефективність використання ресурсів і міркування щодо QoS, PPO пропонує надійний підхід до децентралізованого управління ресурсами в середовищах наскрізного мережевого слайсінгу. Стабільність і надійність алгоритму роблять його придатним вибором для оптимізації розподілу ресурсів, одночасно задовольняючи вимогам QoS у різних слайсах мережі.

Запропонований у роботі підхід до незалежного розподілу ресурсів на основі PPO дозволяє кожному слайсу мережі автономно оновлювати свої мережеві параметри на основі індивідуальних траєкторій. Цей метод має на меті максимізувати глобальну винагороду шляхом навчання політик мережевого агента приймати рішення щодо розподілу ресурсів незалежно для кожного слайсу, тоді як критичні мережі оцінюють функцію цінності для визначення ефективності цих рішень. Спостереження та дії кожного слайсу, включаючи таку інформацію, як тип служби, вхідний вузол, використання ресурсів і ефективність розподілу ресурсів, використовуються у процесі прийняття рішень. Мета полягає в тому, щоб отримати оптимізовану політику, яка

разом максимізує загальну винагороду в усіх слайсах.

Алгоритми передбачають послідовний збір даних протягом визначеного періоду, а потім навчання мережевих агентів для кількох епох. Протягом періоду збору даних спостереження та дії записуються, а траєкторії зберігаються в буферній пам'яті. Згодом, у період навчання, функція переваги оцінюється за допомогою узагальненого методу оцінки переваги, а обрізана сурогатна цільова функція обчислюється для оновлення мережевих агентів. Критичні значення мережі також оновлюються за допомогою функції втрат, щоб мінімізувати розбіжність між прогнозованими та фактичними значеннями.

Незважаючи на те, що в алгоритмах використовується децентралізований підхід до розподілу ресурсів у мережевому слайсінгу, виникає проблема з обмеженнями в точному оцінюванні загального впливу окремих дій слайсів на загальну винагороду. Для її вирішення запроваджується підхід спільного розподілу ресурсів на основі PPO, спрямований на покращення координації між слайсами шляхом спільного оновлення критичних мереж усіх слайсів. Цей метод спрямований на досягнення кращої оцінки глобальної функції значення стану, тим самим підвищуючи оптимізацію розподілу ресурсів між кількома слайсами для максимізації загальної винагороди.

Також вивчається якість обслуговування (QoS) за різних рівнів навантаження на мережу, оцінюючи продуктивність різних алгоритмів розподілу ресурсів. Результати показують, що зі збільшенням навантаження на мережу запропоновані алгоритми спільного розподілу ресурсів на основі PPO і незалежного спільного розподілу ресурсів на основі PPO ефективно балансують ресурси між слайсами для задоволення майбутніх потреб. Для порівняння, інші методи, такі як пропорційний розподіл (PD), демонструють нижчу продуктивність через їх стратегії реактивного розподілу ресурсів. Хоча Fixed Ratio (FR) добре працює за низьких навантажень на мережу, його ефективність зменшується зі збільшенням навантаження. Досліджено ефективність використання ресурсів за змінних навантажень мережі, виявивши, що запропоновані алгоритми досягають високого рівня використання мережевих потужностей, забезпечуючи QoS порівняно з традиційними методами. Погана продуктивність PD пояснюється її нездатністю адаптуватися до раптових змін попиту, незважаючи на виділення надлишкових ресурсів. Подібним чином підхід статичного розподілу FR призводить до низького рівня використання, особливо за сценаріїв низького попиту. Ці результати підкреслюють важливість адаптивних стратегій розподілу ресурсів, особливо в динамічних мережевих середовищах.

Крім того, робота досліджує компроміс між QoS і використанням ресурсів шляхом зміни ваги винагороди. Результати показують, що збільшення вагового коефіцієнта для QoS значно покращує задоволеність QoS, одночасно зменшуючи використання ресурсів. Цей компроміс підкреслює необхідність оптимізації ваги винагороди для досягнення балансу між якістю обслуговування та ефективністю використання ресурсів. Крім того, досліджується розподіл ресурсів відповідно до типів послуг, демонструючи, як різні служби розподіляють ресурси між мережевими рівнями. Результати підкреслюють ефективність розроблених алгоритмів у розподілі ресурсів на основі характеристик сервісу, забезпечуючи оптимальне використання ресурсів у сценаріях наскрізного мережевого слайсінгу. Незважаючи на проблеми масштабності, пов'язані з методами RL, запропоновані алгоритми демонструють

багатообіцяючу продуктивність навіть у складних мережевих топологіях, хоча й із різною швидкістю конвергенції.

Дослідження заглиблюється в динамічний розподіл ресурсів у мережевому слайсінгу в рамках різнорідних вимог у середовищах МЕС для підвищення ефективності використання ресурсів і забезпечення якості обслуговування. Формулюючи проблему як спільну багатоагентну задачу, дослідження розробляє алгоритми незалежної та спільної кооперативної оптимізації проксимальної політики з використанням підходу РРО. Результати моделювання демонструють кращу продуктивність запропонованих алгоритмів порівняно з існуючими методами, особливо підкреслюючи здатність алгоритмів досягати збалансованого розподілу ресурсів між різними типами послуг в ієрархічному середовищі МЕС. Запропонована робота має значний потенціал для вдосконалення управління мережевим слайсінгом у різних мережах, включаючи 5G і не тільки, а також у промислових мережах, вирішення проблем, пов'язаних зі збільшенням складності мережі та необхідністю підтримки гетерогенних послуг. Забезпечуючи автоматизоване й ефективне управління ресурсами, результати дослідження пропонують практичні рішення для майбутніх реалізацій мережевого слайсінгу, що є необхідним для оптимізації розподілу ресурсів і зниження витрат на управління в динамічних мережевих середовищах.

### Література

1. Andronie, Mihai, et al. "Big data management algorithms in artificial Internet of Things-based fintech." *Oeconomia Copernicana* 14.3 (2023): 769-793.
2. Hussain, Fatima, et al. "Machine learning for resource management in cellular and IoT networks: Potentials, current solutions, and open challenges." *IEEE communications surveys & tutorials* 22.2 (2020): 1251-1275.
3. Goudarzi, Shidrokh, et al. "Uav-enabled mobile edge computing for resource allocation using cooperative evolutionary computation." *IEEE Transactions on Aerospace and Electronic Systems* (2023).
4. Kim, Y., H. Lim: Multi-Agent RL-Based Resource Management for End-to-End Network Slicing, *IEEE Access*, Vol. 9, 2021.
5. Liu, Xiaolan, et al. "Resource allocation with edge computing in IoT networks via machine learning." *IEEE Internet of Things Journal* 7.4 (2020): 3415-3426.
6. Lin, Zheng, et al. "Efficient parallel split learning over resource-constrained wireless edge networks." *IEEE Transactions on Mobile Computing* (2024).
7. Tang, Fengxiao, Yibo Zhou, and Nei Kato. "Deep reinforcement learning for dynamic uplink/downlink resource allocation in high mobility 5G HetNet." *IEEE Journal on selected areas in communications* 38.12 (2020): 2773-2782.
8. Xiong, Xiong, et al. "Resource allocation based on deep reinforcement learning in IoT edge computing." *IEEE Journal on Selected Areas in Communications* 38.6 (2020): 1133-1146.