

УДК 621.396.946:004.85

DOI: 10.31673/2412-9070.2025.017038

Л. В. ДАКОВА¹, канд. техн. наук, доцент;
ORCID: 0000-0001-6104-8217

С. Ю. ДАКОВ², канд. техн. наук, доцент;
ORCID: 0000-0001-9413-3709

В. О. ВОЛОШИН¹, аспірант;
ORCID: 0009-0008-6906-6370

Н. О. КОТЕНКО³, канд. педагогіч. наук, доцент,
ORCID: 0000-0002-2675-6514

¹Державний університет інформаційно-комунікаційних технологій, Київ

²Київський національний університет імені Тараса Шевченка

³Державний торговельно-економічний університет, Київ

ПОТЕНЦІЙНІ ПРОБЛЕМИ ЗАСТОСУВАННЯ МОДЕЛЬНО-ОРІЄНТОВАНОЇ ПАРАДИГМИ ПРОЄКТУВАННЯ МОБІЛЬНИХ МЕРЕЖ

У статті аналізуються обмеження традиційної модельної парадигми в мобільних бездротових мережах, такі як складність створення точної моделі та отримання параметрів системи, висока обчислювальна складність і неможливість ефективної декомпозиції без втрат. Аналізується альтернатива у вигляді парадигми, керованої даними, яка використовує сучасні методи машинного навчання для оптимізації мобільних мереж, орієнтуючись на дані, що генеруються самими мережами. Це дозволяє пом'якшити тиск, який створюють швидко змінювані умови та різні навантаження в майбутніх мережах. У статті представлено сценарій використання онлайн-навчання для проактивного балансування навантаження, що дозволяє передбачити сплески трафіку та уникнути перевантажень на етапі налаштування параметрів точок доступу. Таким чином, підхід на основі машинного навчання зменшує перевантаження та покращує ефективність роботи мереж у реальному часі.

Ключові слова: технологія 5G, машинне навчання, модельно-орієнтована парадигма, навантаження, бездротовий зв'язок, мобільна мережа.

Вступ

Постановка проблеми. 5G є наступним етапом у розвитку мобільного зв'язку. Він створений для забезпечення значно вищої швидкості передачі даних, меншої затримки та підвищеної надійності порівняно з попередніми поколіннями, що дозволяє відкривати нові способи використання та змінювати різні галузі.

Мережі 5G здатні підтримувати значно більше пристроїв одночасно та працювати з ресурсомісткими програмами, як-от віртуальна і доповнена реальність, автономні транспортні засоби та Інтернет речей (IoT). Завдяки 5G з'явилися нові інноваційні можливості в сферах охорони здоров'я, виробництва, транспорту та розваг. 5G також є рушійною силою для технологій, як-от периферійні обчислення та штучний інтелект. Із розгортанням мереж 5G мобільними операторами по всьому світу ця технологія продовжує зростати і впродовж 2020-х років ми ще побачимо нові цікаві варіанти її використання.

Через складність аналізу мережевої потужності у термінах теорії інформації багато рішень базуються на спрощених моделях. Наприклад, управління перешкодами між осередками часто спрощується з використанням стохастичних графових моделей, де перешкоди вважаються просто "шумом".

Новий підхід передбачає перехід від традиційних математичних моделей до систем, керованих даними, де комунікаційні технології засновані на реальних даних. Машинне навчання

є ключовим елементом таких мереж, оскільки дозволяє адаптуватися та вдосконалюватися на основі накопичених даних, мінімізуючи залежність від штучних моделей. Завдяки розвитку алгоритмів і зниженню вартості обчислень машинне навчання стає важливим у багатьох галузях науки, техніки та бізнесу.

Аналіз останніх досліджень. Одна з робіт [1] стосується використання нових методів глибокого навчання в майбутніх мережах бездротового зв'язку. В ній показано, що підходи, керовані даними, не повинні замінювати, а радше доповнювати традиційні методи проектування, засновані на математичних моделях. Наведено велику мотивацію, чому глибоке навчання на основі штучних нейронних мереж стане незамінним інструментом для проектування та експлуатації майбутніх мереж бездротового зв'язку, а також представлено бачення того, як штучні нейронні мережі мають бути інтегровані в архітектуру майбутніх мереж бездротового зв'язку.

В іншій роботі [2] йдеться про п'яте покоління стільникових мереж, яке спиратиметься на розгортання периферійних хмар, щоб задовольнити потреби майбутніх додатків у наднизькій затримці. У цій статті автори стверджують, що такі розгортання також можна використовувати для активації розширених програм, керованих даними та машинного навчання (ML), у мобільних мережах. Автори пропонують архітектуру на основі периферійного контролера для стільникових мереж і оцінюють продуктивність за допомогою реальних даних із сотень базових станцій великого оператора США.

У роботі [3] проводиться порівняння парадигми, що керується даними, а також тієї, що орієнтується на моделі. Показані переваги керування за допомогою даних в порівнянні з методологією, яка спирається на моделі. Також автори статті пояснюють, як керована даними парадигма з використанням найсучасніших методів машинного навчання може стати перспективним рішенням. Також розглядається типовий випадок використання парадигми, керованої даними, тобто проактивного балансування навантаження, у якому онлайн-навчання використовується для попереднього налаштування конфігурацій стільників, щоб уникнути різких перевантажень, спричинених швидкими змінами трафіку.

Постановка задачі. Проаналізувати традиційну модельно-орієнтовану парадигму та обґрунтувати, чому вона може бути менш ефективною і практичною для майбутніх мереж 5G та наступних поколінь. Дослідити переваги керованої даними парадигми як перспективного підходу для подолання нових викликів, які не здатна вирішити модельно-орієнтована парадигма.

Основна частина

Серед методів машинного навчання найбільш поширеним є кероване навчання (supervised learning), яке активно застосовується в системах, наприклад, розпізнаванні зображень. Контрольоване навчання передбачає вивчення відображення між набором вхідних змінних X і вихідною змінною Y і застосування цього відображення для прогнозування виходів для невидимих даних. Контрольоване навчання є найважливішою методологією машинного навчання, а також має центральне значення в обробці мультимедійних даних [4].

Неконтрольоване навчання (unsupervised learning) є іншою класичною парадигмою, орієнтованою на роботу з немаркованими даними. Неконтрольоване навчання вивчає, як системи можуть навчитися представляти певні шаблони вхідних даних у спосіб, який відображає статистичну структуру загальної колекції шаблонів вхідних даних. На відміну від керованого навчання або навчання з підкріпленням, немає чітких цільових результатів або оцінок навколишнього середовища, пов'язаних з кожним входом; скоріше учень без нагляду використовує попередні упередження щодо того, які аспекти структури вхідних даних мають бути зафіксовані у вихідних даних [5].

Навчання з підкріпленням – це техніка машинного навчання, яка навчає програмне забезпечення приймати рішення для досягнення найбільш оптимальних результатів. Він імітує процес навчання методом проб і помилок, який використовують люди для досягнення своїх цілей. Дії

програмного забезпечення, спрямовані на досягнення мети, посилюються, тоді як дії, які відволікаються від мети, ігноруються [6].

Математичне моделювання, що використовує математичну мову для опису систем, стало основою сучасної науки і техніки у багатьох сферах. У розвитку мобільного бездротового зв'язку воно дозволяє інтерпретувати, обчислювати та перевіряти різні технічні аспекти, тому стало стандартом для досліджень у мережах до 5G. Однак ця модельно-орієнтована парадигма має обмеження, які можуть заважати подальшому розвитку бездротових мереж.

Успішність моделі залежить від її здатності точно відображати поведінку бездротових мереж. З розвитком стільникових мереж їх математичні моделі ускладнюються через необхідність охоплення нових технологій. Наприклад, модель мережевої топології розвивалася від простої шестикутної структури до складних графів з кількома рівнями точок доступу, що дозволяє мережам збільшувати пропускну здатність у місцях із підвищеним навантаженням. Аналогічно, моделі планування ресурсів трансформувалися від базових до складних процесів для підтримки кількох типів сервісів із різними вимогами до швидкості та затримки.

На жаль, деякі надскладні задачі важко точно описати статистичними моделями. Наприклад, керування перешкодами у традиційних мережах ускладнюється через вплив багатьох факторів, як-от трафік, мобільність користувачів, швидкість їх руку і стратегії балансування навантаження, які впливають на різні показники продуктивності. Для таких складних задач часто застосовуються спрощені моделі з емпіричними параметрами, де потрібно проводити ітеративні вимірювання й налаштування для адаптації мережі при її розгортанні. Подібні труднощі виникають у задачах управління покриттям та передачею, які через складність неможливо точно описати статистичними методами. З появою нових можливостей у мережах 5G і новіших технологіях, традиційна модельно-орієнтована парадигма може стати неефективною або навіть недієздатною.

Статистичні моделі не можуть враховувати надто детальну інформацію, через нестачу статистичних даних, які можуть мати критичне значення у складних сценаріях мереж 5G і наступних поколінь. Наприклад, у надщільних мережах, де кількість точок доступу та користувачів приблизно рівна, точні дані про мобільність кожного користувача істотно впливають на ефективність мережі — зокрема, на формування віртуальних комірок, асоціацію користувачів, вибір режиму передачі та стратегію передачі. Однак для мобільності окремого користувача не існує точної моделі, тому найкраще використовувати необроблені дані про його місцезнаходження та швидкість. Інші приклади включають дані про запити на контент у мобільному граничному кешуванні та параметри каналу в складних середовищах. У складних сценаріях, де потрібні максимально точні дані, статистичні моделі втрачають ефективність через розрідженість і різноманітність інформації.

У мережах до 5G, завдяки їхній однорідності, проблеми, описані статистичними моделями, можна вирішити класичними методами оптимізації, а іноді навіть закритими рішеннями. Щоб уникнути експоненційної складності, такі задачі зазвичай розділяють на підзадачі або використовують евристичні, що дають неоптимальні, але прийнятні рішення. Однак навіть такі рішення можуть вимагати значних обчислювальних ресурсів через масштаб задачі.

Обчислювальна складність ще більше зростає через гетерогенність і різноманітність, які привносять нові можливості 5G, зокрема підтримка кількох технологій радіодоступу, багатократних з'єднань для кожного користувача, різних типів послуг та вимог до якості обслуговування. Очікується, що 5G підтримуватиме до 1 мільйона підключених пристроїв на квадратний кілометр, а у надщільних сценаріях відстань між точками доступу становитиме лише кілька метрів. Керування таким обсягом пристроїв і точок доступу, що розташовані близько один до одного, вимагає об'єднаного розгляду і суттєво збільшує обчислювальну складність, яка стає вузьким місцем у розвитку 5G та наступних мобільних мереж.

Для створення чіткої моделі мобільних бездротових мереж модельна парадигма повинна охоплювати багато системних параметрів. Наприклад, масивні MIMO-системи [7] потребують даних про канали у реальному часі для різних користувачів на різних частотах і антенах для

оптимізації спрямування променів; транспортні мережі вимагають точної інформації про місце й швидкість кожного транспортного засобу для оптимального кластерування; надщільні мережі потребують інформації про потужність міжстільникових перешкод для асоціації користувачів; нарізка мережі вимагає налаштування трафіку для ефективного розподілу ресурсів, а мобільні периферійні обчислення — даних про споживання ресурсів для кожної служби. Проте технічні обмеження та високе споживання ресурсів часто роблять отримання цих параметрів недосяжним. Крім того, сумісність між пристроями різних виробників обмежує обсяг спільних параметрів, що доступні в мережі, через що модельна парадигма стає менш практичною.

У традиційних мобільних мережах мережу розділяють на рівні з окремими функціональними блоками. Це дозволяє розбити складну систему на підпроблеми, кожен з яких можна змоделювати окремо, що значно прискорює дослідження, оскільки фахівці можуть працювати над окремими компонентами. Наприклад, на фізичному рівні комунікаційний процес розділяється на кодування каналу, модуляцію, які оптимізуються окремо у мережах до 5G. Управління радіоресурсами теж розбивають на підзадачі, такі як управління міжстільниковими перешкодами, асоціація користувачів і планування ресурсів. Проте такий підхід не завжди є оптимальним, оскільки підзадачі можуть бути взаємопов'язані. Наприклад, на ефективність кодування може впливати модуляція, а на управління міжстільниковими перешкодами — стратегія асоціації користувачів і планування ресурсів. У мережах 5G і далі зв'язки між різними блоками посилюються через більшу щільність пристроїв і розмаїття типів послуг. Наприклад, у надщільних мережах управління перешкодами, асоціація користувачів і планування ресурсів можуть мати значний вплив один на одного. Тому, для досягнення кращих результатів у 5G і майбутніх мережах необхідно переглянути звичну блочну структуру мереж.

Звичайна модельна парадигма стикається з труднощами у створенні точних моделей та системних параметрів, а також у вирішенні задач оптимізації без високих обчислювальних витрат. Цей підхід може виявитися менш ефективним у нових мережах 5G і далі. У мережах, керованих даними, обробляється великий обсяг інформації, зібраної із різних джерел (параметри каналів, рівень завад, загальне енергоспоживання і т.д.). Ці дані використовуються як на периферійних, так і на хмарних платформах, що забезпечують управління мережею за допомогою навчальних алгоритмів.

Основна особливість підходу, керованого даними, - уніфікована база даних для всіх мережевих функцій, яка заміняє окремі математичні моделі з різними спрощеннями. Це дозволяє уникнути розриву між мережевими функціями, які виконуються на різних рівнях. Наприклад, периферійні обчислення підтримують задачі низького рівня, як-от кодування каналів, тоді як хмарні обчислення забезпечують глобальні дані для високорівневих задач, як-от управління завадами. На відміну від модельної парадигми, підхід керування даними дозволяє вирішувати задачі мобільних мереж без необхідності точного моделювання. Це забезпечує переваги у роботі з детальною інформацією та складними завданнями для мереж 5G та інших технологій.

Алгоритми машинного навчання дозволяють розв'язувати надскладні завдання у комунікаційних мережах за прийнятної обчислювальної складності. У керованій даними парадигмі можна використовувати будь-які доступні дані, які мають значення для задачі. Наприклад, традиційно у моделях використовують лише силу прийнятого сигналу для оцінки міжстільникових перешкод, нехтуючи додатковими деталями, як-от навантаження на точках доступу або мобільність користувачів, щоб зберегти простоту моделі. Однак у керованій даними парадигмі вся доступна інформація може бути залучена і навіть неповні дані стають корисними завдяки алгоритмам навчання. У багатьох випадках сирі дані, створені мережею, спершу обробляються для отримання релевантних характеристик, які потім використовуються для підвищення ефективності моделей навчання.

Гнучкість параметрів значно сприяє реалізації керованої даними парадигми у мобільних бездротових мережах. Наприклад, у системах Massive MIMO часткові параметри каналу мо-

жна використовувати як вхідні дані, уникаючи неточностей, що виникають через лінійну інтерполяцію повних параметрів каналу. У мережах із різномірними точками доступу спільні функції можна витягнути з кожної точки, що дозволяє застосувати єдиний алгоритм машинного навчання по всій мережі. Парадигма, керована даними, використовує лише доступні дані, що усуває розрив між реальними і штучними параметрами, на відміну від парадигми на основі моделі.

У модельній парадигмі складні завдання розділяють на кілька менш складних, які вивчаються окремо. Проте у майбутніх мережах 5G і далі зв'язок між різними мережевими функціями посилюється. Керована даними парадигма дозволяє об'єднати тісно пов'язані проблеми в єдиній технічній структурі, наприклад, кодування і модуляцію на фізичному рівні, управління перешкодами та асоціацію користувачів на рівні мережі і навіть питання розподілу радіоресурсів. Це дозволяє уникнути зайвої декомпозиції і спрощення, характерних для традиційної парадигми на основі моделей.

Через непередбачуваність поведінки користувачів і динаміку бездротового середовища, трафік у мобільних мережах може бути нерівномірним у просторі та змінним у часі. Це призводить до неефективного використання радіоресурсів і перевантаження точок доступу, що стає ще більш актуальним з ростом щільності мереж і неоднорідності в 5G і майбутніх системах. Балансування навантаження — один із ключових напрямків досліджень мобільних мереж.

Традиційне балансування навантаження є трудомістким і схильним до помилок процесом, який потребує ручного налаштування параметрів. Інженери регулюють потужність опорного сигналу та нахил антен на основі тестувань та скарг користувачів. Щоб усунути недоліки ручного балансування, розроблені схеми автоматичного балансування, де конфігурації оновлюються автоматично, щоб ліквідувати дисбаланс трафіку у реальному часі. Під час автоматичного балансування оцінюється навантаження на комірки з урахуванням різних показників, таких як потужність передачі, використання радіоресурсів, рівень перешкод, пропускна здатність і стабільність зв'язку.

Параметри комірки, як-от потужність опорного сигналу, нахил антени, пороги для повторного вибору комірки та зміщення передачі, періодично налаштовуються відповідно до звітів мережі у реальному часі, щоб уникнути перевантаження. Для забезпечення стабільності мережі кожне налаштування параметрів повинно відповідати певному діапазону, тому оптимальне налаштування іноді потребує багаторазових коригувань. Проте за високої відмінності щільності трафіку між двома базовими станціями, реактивне балансування навантаження може не встигати налаштувати комірки під сплески трафіку. У таких випадках доцільно використовувати проактивне балансування навантаження, де налаштування параметрів виконуються до того, як у комірці виникне сплеск трафіку.

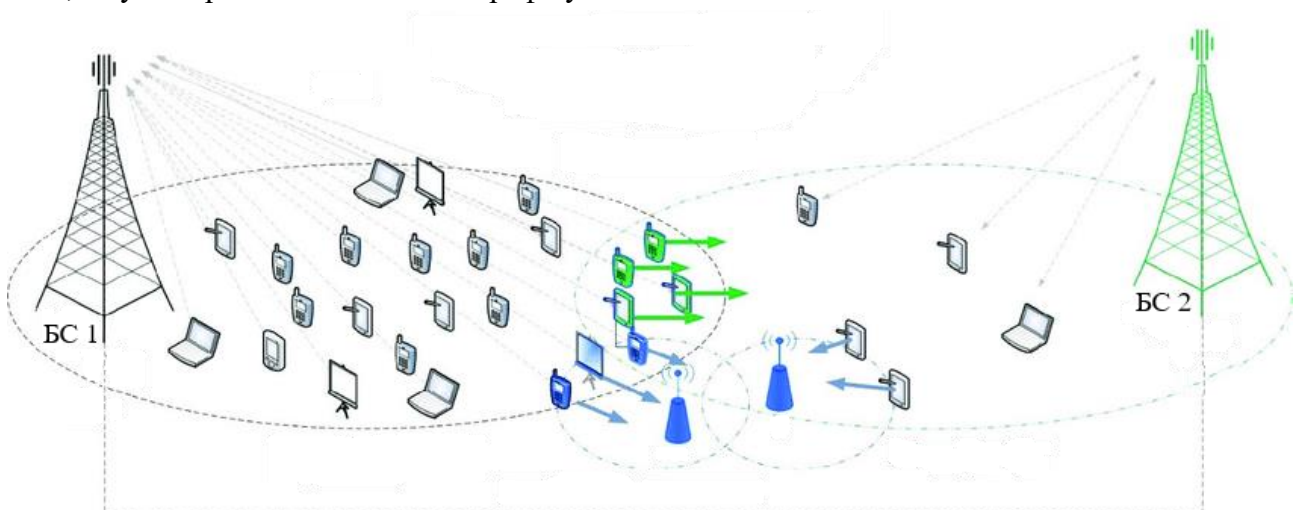


Рис. 1. Процес перемикання навантаження з однієї базової станції на іншу у зв'язку із збільшенням навантаження на одну з них

На рис. 1 [8] зображено проактивне балансування навантаження на прикладі двох базових станцій (БС). Дві БС покривають певну територію. При чому в зоні покриття БС 1 знаходиться на порядок більше абонентів, ніж у зоні покриття БС 2. Також є певна зона, де покриття обох БС перетинається. Завдяки проактивному налаштуванню параметрів можна переключити абонентів, які знаходяться у спільній зоні покриття, на менш завантажену станцію.

У вже згаданій раніше роботі [3] автори дослідження розглядають дещо інший випадок, в якому транспортний засіб з великою кількістю пасажирів проїжджає через зону дії кількох базових станцій. Згідно цього дослідження це може призвести до зростання трафіку на 10 Гбіт/с протягом 10 секунд для однієї базової станції. Існуюча техніка балансування може не впоратися з таким навантаженням, оскільки в момент потрапляння транспортного засобу у зону дії БС її конфігурація не готова до такого навантаження. Для того, щоб впоратися з таким навантаженням автори статті пропонують передбачати, коли та де такий трафік може виникнути, тому пропонується використати алгоритми послідовного онлайн-навчання. Де в будь який момент t алгоритм навчання повинен дати відповідь p_t у даній поточній інформації $x_t \in X$. У наступний момент часу $t + 1$ з'являється правильна відповідь попереднього завдання, яку позначають $y_t \in Y$ і алгоритм, який навчається, зазнає втрат, отриманих від $l(p_t, y_t)$. Кінцевою метою онлайн навчання є мінімізація загальних втрат, спричинених некоректними передбаченнями, зробленими через $\sum_{t=1}^T l(p_t, y_t)$ для T циклів. Класичні статистичні методи можуть впоратися з таким завданням, якщо існує чітка кореляція між минулим та теперішнім. Але зазвичай на практиці таке припущення не задовольняється. Замість того, щоб зосереджуватися на мінімізації фактичних втрат, більшість алгоритмів онлайн-навчання спрямовані на мінімізацію $Regret_T(h)$ порівняно з гіпотезами $h: X \rightarrow Y$ із скінченного простору гіпотез H . Тому, для $h \in H$, $Regret_T(h) = \sum_{t=1}^T l(p_t, y_t) - \sum_{t=1}^T l(h(x_t), y_t)$. А для всього простору гіпотез $Regret_T(H) = \max_{h \in H} Regret_T(h)$. Таким чином, було запропоновано різноманітні алгоритми з "низьким рівнем шкодування" (наприклад, алгоритм Follow The Leader), у яких рівень шкодування зростає сублінійно зі збільшенням T . Ці алгоритми з "низьким рівнем шкодування" гарантують, що середні втрати в кожному раунді будуть такими ж ефективними, як і найкраща гіпотеза в множині H , коли T прямує до нескінченності. Якщо область прогнозування Y є опуклою множиною, а функція втрат $l: Y \rightarrow R$ є опуклою, техніки онлайн-оптимізації опуклих функцій можуть бути застосовані для прискорення процесу навчання.

Таким чином, для точного передбачення сплесків трафіку можна використовувати методи онлайн-навчання, що дозволяють здійснювати послідовні прогнози. На кожному етапі алгоритм дає відповідь на прогноз, спираючись на поточну інформацію, а на наступному етапі коригує свою відповідь на основі результатів попереднього раунду. Метою онлайн-навчання є мінімізація загальних помилок прогнозування. Класичні статистичні методи можуть застосовуватися в умовах, коли минулі дані мають сильний зв'язок із поточними, що дозволяє забезпечити точність прогнозів при дотриманні певних умов і явної форми функції втрат.

Проактивне балансування навантаження на основі онлайн-навчання, у цій системі кожна точка доступу самостійно прогнозує трафік, використовуючи алгоритми онлайн-навчання, тоді як центральний координатор здійснює глобальне балансування, налаштовуючи параметри комірок у цільовій зоні. На кожному етапі предиктори отримують дані від сусідніх комірок, зокрема історичні дані про швидкість та асоціації користувачів і прогнозують можливі сплески трафіку на наступному кроці. Балансувальник навантаження об'єднує цю інформацію та повертає оптимальні налаштування комірок для зменшення заторів. Потім точки доступу змінюють параметри своїх комірок ще до початку сплеску трафіку. Цикл таких дій дозволяє ефективно зменшувати перевантаження, спричинені різкими змінами трафіку.

Порівнюючи підхід, в якому використовується машинне навчання, онлайн навчання та проактивне балансування навантаження, можна побачити, що такий метод може бути більш ефективним, оскільки він передбачає прогнозування трафіку і внесення змін в систему ще до виникнення сплеску трафіку. Тоді, як класичний підхід передбачає балансування у реальному часі і в ситуації описаній вище такий підхід може призвести до суттєвого погіршення якості зв'язку.

Висновки

У результаті аналізу традиційної модельної парадигми в мобільних бездротових мережах було виявлено кілька важливих недоліків, зокрема складність точного визначення моделей і параметрів системи, висока обчислювальна складність та обмеження у створенні ефективних декомпозицій без втрат. Замість цього, парадигма, керована даними, що використовує методи машинного навчання, виявляється набагато ефективнішою в умовах швидко змінюваних і динамічних мобільних мереж. Такий підхід дозволяє будувати мережі на основі даних, які вони генерують, що зменшує залежність від статичних моделей та параметрів.

Один із основних аспектів цієї парадигми — використання онлайн-навчання для проактивного балансування навантаження. Це дозволяє передбачати можливі сплески трафіку та відповідно налаштовувати параметри мережі ще до їхнього виникнення, тим самим зменшуючи перевантаження та підвищуючи ефективність роботи мережі у реальному часі. Застосування цієї технології дозволяє адаптувати мережу до динамічних умов, таких як швидкі зміни у навантаженні в одних місцях і зниження навантаження в інших.

Таким чином, парадигма, керована даними, має великий потенціал для розвитку мобільних бездротових мереж майбутнього. Вона здатна вирішувати проблеми, які виникають у традиційних підходах, та відкриває нові можливості для створення більш адаптивних і ефективних мереж, що можуть забезпечити безперервне та швидке обслуговування в умовах змінного трафіку.

Список літератури

1. A. Zappone, M. Di Renzo and M. Debbah, "Wireless Networks Design in the Era of Deep Learning: Model-Based, AI-Based, or Both?," in *IEEE Transactions on Communications*, vol. 67, no. 10, pp. 7331-7376, Oct. 2019, doi: 10.1109/TCOMM.2019.2924010
2. M. Polese, R. Jana, V. Kounev, K. Zhang, S. Deb and M. Zorzi, "Machine Learning at the Edge: A Data-Driven Architecture With Applications to 5G Cellular Networks," in *IEEE Transactions on Mobile Computing*, vol. 20, no. 12, pp. 3367-3382, 1 Dec. 2021, doi: 10.1109/TMC.2020.2999852
3. T. Wang, S. Wang and Z.-H. Zhou, "Machine learning for 5G and beyond: From model-based to data-driven mobile wireless networks," in *China Communications*, vol. 16, no. 1, pp. 165-175, Jan. 2019, doi: 10.12676/j.cc.2019.01.015
4. Cunningham, P., Cord, M., Delany, S.J. (2008). *Supervised Learning*. In: Cord, M., Cunningham, P. (eds) *Machine Learning Techniques for Multimedia. Cognitive Technologies*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-540-75171-7_2
5. Dayan, Peter, Maneesh Sahani, and Grégoire Deback. "Unsupervised learning." *The MIT encyclopedia of the cognitive sciences* (1999): 857-859.
6. What is Reinforcement Learning? - Reinforcement Learning Explained - AWS. Amazon Web Services, Inc. URL: <https://aws.amazon.com/what-is/reinforcement-learning>
7. T. L. Marzetta, "Massive MIMO: An Introduction," in *Bell Labs Technical Journal*, vol. 20, pp. 11-22, 2015, doi: 10.15325/BLTJ.2015.2407793
8. Shaye, Ibraheem & Ergen, Mustafa & Bin Azmi, Marwan & Aldirmaz, Sultan & Nordin, Rosdiadee & Daradkeh, (2020). *Key Challenges, Drivers and Solutions for Mobility Management in 5G Networks: A Survey*. *IEEE Access*. 8. 172534-172552. 10.1109/ACCESS.2020.3023802.

L. Dakova, S. Dakov, V. Voloshyn, N. Kotenko

POTENTIAL PROBLEMS OF APPLYING THE MODEL-ORIENTED PARADIGM IN MOBILE NETWORK DESIGN

In this paper, we address the limitations of the traditional model-based paradigm in mobile wireless communication networks, such as the complexity of defining accurate models, obtaining system parameters, high computational demands, and the inability to create lossless block decompositions. These challenges hinder the effective use of model-based approaches in dynamic, evolving mobile networks.

We analyze the data-driven paradigm, supported by advanced machine learning techniques, as a solution. Unlike model-based approaches, which depend on predefined network models and parameters, the data-driven paradigm builds networks directly on data generated by the network itself. This approach efficiently handles real-time, dynamic data, bypassing the need for static models. We investigate one of a typical use case where this paradigm is applied to implement proactive load balancing. A key feature of this approach is online learning, which enables networks to predict traffic spikes before they occur and adjust network parameters accordingly. This proactive strategy minimizes congestion and improves efficiency by anticipating traffic surges, such as those caused by big groups of users which are moving between base stations. The paper describes how online learning methods are used to predict and avoid packet overloads due to rapid traffic changes, especially in mobile networks with varying data rates. We also investigated load balancing using online learning, where access points independently predict traffic based on neighboring cells' data, and a central load balancer adjusts cell configurations to reduce congestion. Proactive adjustments are made before traffic spikes, ensuring minimized disruptions.

In conclusion, the data-driven paradigm, combined with machine learning, offers significant advantages over traditional approaches, particularly in scalability, flexibility, and real-time adaptability. As mobile networks evolve, further research into these methods will be crucial for more efficient, intelligent communication systems.

Keywords: 5G, model-based approach, data, mobile wireless networks, machine learning, traffic prediction, load balancing, computational complexity.
