

<https://doi.org/10.31891/2307-5732-2023-317-1-33-41>

УДК 621.391

ВАСИЛЬКІВСЬКИЙ Микола

Вінницький національний технічний університет

<https://orcid.org/0000-0002-6586-2563>e-mail: mvasylkivskyi@gmail.com**ПРИКМЕТА Андрій**

Вінницький національний технічний університет

e-mail: botan.mua@gmail.com**ОЛІЙНИК Андрій**

Вінницький національний технічний університет

e-mail: w0lfend00@gmail.com**НІКІТОВИЧ Діана**

Вінницький національний технічний університет

<https://orcid.org/0000-0002-8907-1221>e-mail: diananikitovych@gmail.com

ОПТИМІЗАЦІЯ ІНТЕЛЕКТУАЛЬНИХ ТЕЛЕКОМУНІКАЦІЙНИХ МЕРЕЖ

В роботі наведено результати досліджень особливості використання машинного навчання в телекомунікаційних мережах та здійснено опис основ теорії штучного інтелекту. Визначено характер впливу динамічної байєсівської мережі (DBN) та DNN на розвиток багатьох технологій, включаючи виявлення активності користувача, оцінку каналу та відстеження мобільності. Розглянуто показники ефективності комунікацій на основі теорії інформаційних вузьких місць, яка знаходиться на стику машинного навчання та прогнозування, статистики і теорії інформації. Наведено математичні вирази оптимізації функціональних характеристик радіомереж 5G/6G з використанням нових, достатньо формальних і водночас універсальних математичних інструментів з акцентом на технології глибокого навчання, що дозволяють проводити систематичний, надійний та інтерпретований аналіз великих випадкових мереж та широкий спектр їх мережевих моделей і практичних мереж.

Ключові слова: глибока нейронна мережа, багатоагентне навчання з підкріпленням, динамічна байєсівська мережа, надроздільна здатність, прихована марківська модель, бездротовий канал.

VASYLKIVSKYI Mikola, PRYKMETA Andrii, OLIYNYK Andrii, NIKITOVYCH Diana
Vinnytsia National Technical University

OPTIMIZATION OF INTELLIGENT TELECOMMUNICATION NETWORKS

The paper presents the results of research on the use of machine learning in telecommunication networks and describes the basics of the theory of artificial intelligence. The impact of dynamic Bayesian network (DBN) and DNN on the development of many technologies, including user activity detection, channel estimation, and mobility tracking, is determined. The indicators of the effectiveness of communications based on the theory of information bottlenecks, which is at the junction of machine learning and forecasting, statistics and information theory, are considered. A neural network model that is pretrained for high-level tasks and divided into transmitter-side and receiver-side uses is investigated. The process of learning the model, which is performed after its adjustment, taking into account the existing transmission channels, is considered.

New ANN learning techniques capable of predicting or adapting to sudden changes in a wireless network, such as federated learning and multiagent reinforcement learning (MARL), are reviewed. The DBN model, which describes a system that dynamically changes or develops over time, is studied. The considered model provides constant monitoring of work and updating of the system and prediction of its behavior.

Distributed forecasting of channel states and user locations as a key component in the development of reliable wireless communication systems is studied. The possibility of increasing the number of degrees of freedom of the generalized wireless channel $G(E)$ in terms of: the physical propagation channel, the directional diagram of the antenna array and mutual influence, electromagnetic physical characteristics is substantiated. The impact of ultra-high-resolution theory on the development of many technologies, including localization algorithms, compressed sampling, and wireless imaging algorithms, is also identified.

Mathematical expressions for optimizing the functional characteristics of 5G/6G radio networks are presented using new, sufficiently formal and at the same time universal mathematical tools with an emphasis on deep learning technologies, which allow systematic, reliable and interpretable analysis of large random networks and a wide range of their network models and practical networks.

Keywords: deep neural network, multi-agent reinforcement learning, dynamic Bayesian network, super-resolution, hidden Markov model, wireless channel.

Постановка проблеми у загальному вигляді та її зв'язок із важливими науковими чи практичними завданнями

У багатьох сучасних інженерних галузях інфокомунікаційні та радіотехнічні системи мають тенденцію організовуватися у великі мережі (такі як надмасивні МІМО і щільні мережі). Крім того, підвищується важливість системної динаміки, оскільки при цьому потрібна швидка обробка даних в середовищах, що швидко змінюються. Виступаючи свого роду спільним знаменником, такі мережі тепер стикаються з проблемою, пов'язаною з необхідністю одночасно справлятися зі зростаючим розміром телекомунікаційної радіосистеми (збільшення вузлів у мережах та збільшення суб'єктів, що взаємодіють з ними), підвищенням рівнем стохастичності (випадкові зміни в топології та випадковий розвиток середовища), а також з потребою в децентралізованій та самоорганізованій обробці даних (мережні вузли повинні бути автономними і здатні динамічно адаптуватися до середовища, що змінюється). Ці три аспекти

є основними компонентами, необхідними при моделюванні, аналізі та оптимізації продуктивності майбутніх мереж. В традиційних методах для вирішення подібних проблем у великих складних інфокомунікаційних радіосистемах використовуються пряме моделювання (метод Монте-Карло) або евристичні інструменти, такі як нейронні мережі або рої частинок [1]. Однак вони мають ряд серйозних недоліків, наприклад вони не є математично стабільними і погано піддаються простій інтерпретації, внаслідок чого спрямовані на покращення та оптимізацію системи або засновані на пробах та помилках, або просто неможливі. У результаті ці методи часто розглядаються як резервні рішення у випадках, коли математичні моделі не мають міцної основи [2]. Отже, потрібна розробка нових теоретичних інструментів, що дозволяють проводити систематичний, надійний та інтерпретований аналіз великих випадкових мереж. Ці інструменти повинні бути достатньо формальними, щоб охоплювати широкий спектр мережевих моделей, але водночас універсальними для забезпечення легкої спеціалізації для практичних мереж.

Аналіз останніх джерел

Для вирішення частини проблем, властивих великим інфокомунікаційним системам вже було визначено різні сучасні математичні інструменти. Однак більшість цих інструментів все ще знаходяться на ранніх стадіях математичного опрацювання або тільки почали впроваджуватися в інженерні дослідження. З цих нових інструментів найбільш перспективними виявилися: теорія випадкових матриць, зокрема теорія випадкових матриць великої розмірності [3], теорія великомірних ермітових матриць з випадковими елементами. На початку перших досліджень у цій галузі спостерігався сплеск інтересу до бездротового зв'язку під час аналізу нових технологій тієї епохи – множинних антен та методів розширення спектру, математичні моделі яких були засновані на випадкових матричних каналах зв'язку [4]. У той час як науковий прогрес у цій галузі продовжувався (на основі математичних результатів), мало хто з дослідників розвивав математичні основи теорії випадкових матриць далі, ніж це було необхідно для вирішення складних проблем. Проте нещодавно у масивному МІМО і надмасивному МІМО з'явилися нові теоретичні інструменти, пов'язані з аналізом мереж бездротового зв'язку [5].

Одночасно із технологією 6G починають з'являтися різні технології, які тісно пов'язані з теорією великомасштабних комунікацій, у тому числі щільна мережа, федеративне навчання, безсотовий масивний МІМО, орієнтований на користувача зв'язок, граничний зв'язок і розподілений МІМО.

Теорія випадкових матриць спрямована на вивчення спектральних властивостей (власних значень і підпросторів) матриць з випадковими елементами, розміри яких вважаються дуже великими. Подібно до того, як випадкові змінні або випадкові вектори кінцевого розміру демонструють детерміновані межі при досягненні великого набору вибірок цих змінних (в основному на основі закону великих чисел або центральної граничної теореми), спектральні діапазони деяких моделей випадкових матриць демонструють детерміновану поведінку, коли розміри рядка та стовпця ростуть до безкінечності. Довгий час ця теорія залишалася прерогативою математиків, проте на початку 2000-х стало очевидним, що випадкові матриці можуть адекватно моделювати канали бездротового зв'язку, які є стохастичними та швидко змінюються за своєю природою [6]. Після кількох років роботи дослідникам бездротового зв'язку стало зрозуміло, що більшість моделей випадкових матриць, запропонованих математиками, або неадекватні, або занадто прості для ефективного вивчення найбільш реалістичних каналів зв'язку. Друга хвиля досліджень почалася приблизно в 2010 році і мала на меті подальше вивчення математичного інструменту теорії випадкових матриць для конкретних потреб інженерів бездротового зв'язку. Останні досягнення в цій галузі принесли важливі нові результати в моделюванні, аналізі та оптимізації продуктивності численних бездротових каналів, таких як канали МІМО точка-точка з райсівським завмиранням, багато-променеві канали МІМО, канали МІМО множинного доступу, передкодовані ширококомовні канали, канали зв'язку з унітарними прекодерами, багатоланкові канали та мережі з одним/декількома осередками [1–3]. Хоча ці результати іноді ґрунтуються на дуже складних системних моделях, вони представлені у відносно спрощеній формі та добре піддаються оптимізації. Істотним інгредієнтом, який вводиться теорією випадкових матриць, є наближення великої розмірності, що дозволяє ефективно аналізувати великі складні стохастичні системи з детермінованими величинами, відомими як детерміновані еквіваленти [1]. Компоненти великорозмірної системи вимірюються на основі кількості антен у бездротових пристроях, кількості користувачів в одному осередку або кількості осередків у цій мережі. Таким чином, теорія випадкових матриць визнана ефективним інструментом для аналізу багатьох локальних систем бездротового зв'язку, де «локальний» розуміється як «одномасштабний» (велика кількість антен, або кількість користувачів). Очікується, що завдяки додатковим узагальненим інструментам, таким як детерміновані ітераційні еквіваленти [2], теорія випадкових матриць стане адекватним інструментом для моделювання складних телекомунікаційних систем, в яких враховуються багато великорозмірних компонентів, що дозволяє уявити собі спільний аналіз на макроскопічному і мікроскопічному рівнях. Крім того, інструменти теорії випадкових матриць також справили враження на співтовариство обробки сигналів, запропонувавши інноваційні схеми детектування та оцінки (статистичного висновку), такі як технологія радарного МІМО, для обробки великих масивів сигналів [3]. Нарешті, було проведено дослідження з розробки децентралізованих алгоритмів для оптимізації продуктивності багатоосередкових мереж МІМО [4] – децентралізована стохастична оптимізація. Другий цікавий інструмент – це нещодавно запропонована структура, що поєднує стохастичні апроксимації та алгоритми пліток (gossip algorithm) для децентралізованої стохастичної оптимізації.

Формулювання цілей статті

Метою роботи є оптимізація функціональних характеристик радіомереж 5G/6G з використанням універсальних математичних інструментів з акцентом на технології глибокого навчання, що дозволяють проводити систематичний, надійний та інтерпретований аналіз великих випадкових мереж та широкий спектр їх мережевих моделей і практичних мереж.

Виклад основного матеріалу

Для інтерпретації глибокої нейронної мережі (DNN) з акцентом на технології глибокого навчання використовується безліч різних теорій, таких як теорія оптимізації, алгоритми максимізації очікування, теорія топології, теорія графів, семантична теорія, теорія динамічних систем та теорія наближень. Вибір відповідної теорії для інтерпретації DNN залежить від реальної проблеми. Одними з найбільш відповідних теорій у контексті бездротового зв'язку є теорія інформації та теорія інформаційних вузьких місць, зокрема, оскільки вони виходять з тієї ж точки зору на теорію інформації, що й бездротові системи. Далі будемо теж дотримуватимемося цієї точки зору.

Одним із показників ефективності комунікацій є теорія інформаційних вузьких місць, яка знаходиться на стику машинного навчання та прогнозування, статистики і теорії інформації [5].

Шенон визначив інформацію, яка є будівельними блоками для теорії глибокого навчання, як невизначеність з імовірнісної точки зору [6].

По-перше, взаємна інформація $I(X; Y)$ відображає ступінь ймовірнісної взаємодії між двома випадковими величинами: X і Y . Якщо змінюється X , то певною мірою буде змінюватися Y , і навпаки: $I(X; Y) = I(Y; X)$. Глибoku нейромережу можна змодельовати як потік взаємної інформації від входу до виходу.

По-друге, порівняльні відношення взаємної інформації $I(X; Y) = I(P_x; P_{y|x})$ включають увігнуту функцію $I(X; Y)$ від змінного P_x і фіксованого $P_{y|x}$ а також опуклу функцію $I(X; Y)$ змінного $P_{y|x}$ та фіксованого P_x . Звідси випливає необхідність кодування $I(X; Y)$ джерела інформації для мінімізації $I(X; Y)$, та кодування каналу для максимізації $I(X; Y)$.

Так само DNN поєднує два змагальних кроки. Для пояснення того, що відбувається в DNN з точки зору теорії інформації, [3] пропонується теорія інформаційного вузького місця з використанням потоку взаємної інформації та змагального характеру підвищення та зниження розмірності. Навчаючи DNN очікується, що вихідний шар Y буде максимально схожий на вхідний шар X , а прихований шар Z максимально відрізнятиметься від вхідного шару X , наскільки це можливо. З погляду теорії інформації це означає максимізацію $I(X; Y)$ при мінімізації $I(X; Z)$. При переході від X до Z відбувається стиснення (кодування) інформації, а під час руху від Z до Y відбувається декодування.

Припустимо, що у прихованому шарі Z є вузьке інформаційне місце y : якщо ентропія Z менша, ніж γ , то вся інформація Z може пройти; в іншому випадку може пройти тільки найбільш істотна γ -частина Z .

Взаємну інформацію між X і Z можна визначити наступним чином:

$$I(X; Z) = \sum_X \sum_Z P_{Z,X} \cdot \log \frac{P_{Z,X}}{P_Z \cdot P_X} = \sum_X \sum_Z P_X \cdot P_{Z|X} \cdot \log \frac{P_{Z|X}}{P_Z} \quad (1)$$

Перехресна ентропія Y дорівнює:

$$H_{cross}(Z, Y) = -\sum_Z P_Z \cdot \log P_{Y|Z} = E_{X \square P_X} \left[-\sum_Z P_{Z|X} \cdot \log P_{Y|Z} \right] \quad (2)$$

З урахуванням інформаційного вузького місця остаточно функція втрат DNN дорівнює:

$$f_{loss} = E_x \square P_X \left[-\sum_Z P_{Z|X} \cdot \log P_{Y|Z} \right] + \beta \sum_X \sum_Z P_X \cdot P_{Z|X} \cdot \max \left(\log \frac{P_{Z|X}}{P_Z} - \gamma, 0 \right) \quad (3)$$

Оскільки математично складно мінімізувати компонент

$$\sum_X \sum_Z P_X \cdot P_{z|x} \cdot \max \left(\log \frac{P_{z|x}}{P_z} - \gamma, 0 \right),$$

альтернативою є мінімізація його верхньої межі $E_{x \square P_X} [D(P_{Z|X} | Q_Z)]$, де $D(P_{z|x} | Q_z)$ – дивергенція (розбіжність) Кульбака Лейблера $P_{z|x}$ по Q_z . В результаті функція втрат набуває наступного вигляду:

$$f_{loss} = E_x \square P_X \left[-\sum_Z P_{z|x} \cdot \log P_{y|z} \right] + \beta \cdot E_x \square P_X [D(P_{z|x} | Q_z)] \quad (4)$$

Функція втрат визначає інформаційне вузьке місце та виявляє глибинний взаємозв'язок між метою навчання, архітектурою нейронної мережі та розподілом вхідних даних [1].

Деякі методи навчання можуть використовувати теорію вузьких інформаційних місць для оптимізації своєї архітектури. Наприклад, варіаційний висновок будує нижню межу мети інформаційного вузького місця та навчається на зібраних даних без попереднього знання про їх розподіл [2]. Ця структура може бути розширена на випадки з різними диспропорціями, що виникають у задачах високого рівня, або на випадки з багатозадачними проблемами [3].

З точки зору архітектури нейронної мережі та методу навчання найпростіше розділити модель нейронної мережі, попередньо навчену для завдань високого рівня на дві частини: одну для використання на

боці передавача, а іншу, для використання на стороні приймача. Потім можна вставити нейронні шари між двома частинами. Після навчання моделі виконується її налаштування з урахуванням існуючих каналів [4].

При неявній реалізації стиснення ($E_x \square P_x [D(P_{z|x} | Q_z)]$) у вигляді DNN використовується автоенкодер (AE) [5]. Коефіцієнт стиснення $|Z|/|X|$ відповідає вибірці даних X , а мета Y априорі невідома. Коли $Y = X$, автоенкодер стає джерелом на основі навчання для блочного коду фіксованої довжини з найнижчим коефіцієнтом стиснення $|Z|/|X|$, який в цілому обмежений знизу $H(X)$. Якщо розмір X недостатньо великий (маленький блок), автоенкодер допоможе знайти вихідний код зі ступенем стиснення $|Z|/|X|$, нижче, ніж $H(X)$.

Варіаційний автоенкодер (VAE) [1] вводить у прихований шар априорний розподіл (Q_z), який є показником сприйняття поверх швидкості та стиснення. Різні априорні розподіли (Q_z) призведуть до різних коефіцієнтів DNN. Якщо Q_z є однорідним багатовимірним розподілом Гауса, проекція по кожному виміру є оцінкою цього виміру. Теоретично Q_z може бути будь-яким іншим розподілом, і, отже, неоднорідні підканали бездротової системи можуть бути змодельовані як Q_z , що дозволяє налаштувати VAE для конкретного раніше відомого розподілу.

На відміну від автоенкодерів, які тільки максимізують $I(X; Y)$, варіаційні автоенкодери працюють за двома конкуруючими напрямками, одночасно мінімізуючи $I(X; Y)$ і максимізуючи $I(X; g_Y(Z; \theta_g))$. Наприкінці навчання $I(X; g_Y(Z; \theta_g))$ представляє собою мінімальну взаємну інформацію (Z), яка присутня у шарі вузького місця. Необхідно враховувати, що варіаційні автоенкодери допомагають генерувати схему кодування загального джерела.

$$\Omega_y(X; \theta) \quad (5)$$

Генеративно-змагальна мережа (GAN) – це великий крок уперед у порівнянні з VAE [3]. У типовій GAN Васерштейна априорні розподіли (QZ) реальні і не є гаусовими образами, а метрика більше не є взаємною інформацією – тепер це відстань Васерштейна. Хоча GAN – одна з кращих генеративних DNN, доступних в даний час, VAE, як і раніше є кращою для систем бездротового зв'язку через наявність прихованого гаусового рівня, оскільки над гаусовими розподілами можна виконувати лінійні операції [6].

На сьогоднішній день глибоке навчання використовується лише у традиційних централізованих архітектурах, тоді як його використання у розподілених архітектурах рідко стає об'єктом досліджень. Це критичне питання з погляду перспектив створення мереж 6G, оскільки розподілені архітектури необхідні для забезпечення масштабованості і гнучкості системи зв'язку. Проте застосування глибокого навчання у розподіленій архітектурі зумовить кілька фундаментальних проблем. Наприклад, у кожного бездротового вузла буде своя власна ANN, яка буде навчена з використанням власного набору даних, отриманого на основі локальних вимірів та досвіду. В результаті різні бездротові вузли повинні навчитися поводитися на основі наборів даних, які можуть відрізнятися як за кількістю (різні вузли можуть мати різні можливості вимірювання та зберігання), так і за якістю (різні вузли можуть відчувати різні спотворення даних через відмінності в датчиках). Це може призвести до нестабільності і, в гіршому випадку, до збою бездротової мережі. Крім того, у розподіленій архітектурі кожен вузол намагатиметься оптимізувати свою власну продуктивність, а не загальносистемну результативність, через врахування інших вузлів як можливих противників. Це може викликати небажані або небезпечні ситуації, в яких бездротовий вузол може навчитися шахраювати, щоб максимізувати свою продуктивність. Отже, дуже важливо отримати тверді знання про всі ці проблеми, щоб гарантувати правильну поведінку вузлів у бездротових мережах на основі ANN. Нарешті, більшість результатів глибокого навчання не передбачають отримання розподілених масштабованих рішень, що враховують великі розміри та непередбачувану еволюцію з часом у сценаріях бездротового зв'язку 6G. В результаті створення відповідних навчальних наборів стає дуже складним завданням, оскільки загальні підходи до навчання з учителем припускають, що ANN працюватимуть в умовах, аналогічних тим, які були представлені на етапі навчання. Насправді раптові зміни трафіку та/або топології можуть зробити доступні навчальні набори марними. Отже, терміново потрібні нові методики навчання ANN, здатні передбачати або принаймні пристосовуватися до раптових змін у бездротовій мережі.

Розглянемо дві такі методики: федеративне навчання (federated learning) та багатоагентне навчання з підкріпленням (MARL). Федеративне навчання – це підхід до машинного навчання, при якому центральна модель навчається децентралізовано [1, 3] з використанням даних на вузлах. Суть процесу полягає в наступному: у кожному раунді кожен вузол незалежно обчислює оновлення для центральної моделі, використовуючи свої збережені дані, а потім передає це оновлення (але не дані) на центральний сервер, який об'єднує оновлення, надіслані з різних вузлів, а потім обчислює покращену глобальну модель.

Сучасні мобільні пристрої зберігають у своїй пам'яті безліч даних, які можна використовувати для навчання моделей. Хоча такі дані можуть значно покращити моделі, вони часто складаються з конфіденційної інформації і тому перебувають у приватній власності. Тому власники зазвичай не хочуть ділитися такими даними із центральним сервером з метою навчання. Щоб обійти цю проблему, сервер може надіслати центральну модель вузлам для навчання на місцях з використанням локальних даних. Після створення оновленої моделі вузли надсилають її на центральний сервер. Таким чином, центральний сервер отримуватиме велику кількість оновлень моделі від багатьох вузлів, які потім об'єднуються в покращену глобальну модель. Після цього починається ще один раунд процесу навчання: центральний сервер

відправляє покращену модель новим вузлам, а нові вузли навчають її далі, використовуючи свої особисті дані. Після багатьох раундів параметри моделі можуть сходитися, у результаті виходить добре навчена модель.

Основна мета федеративного навчання – відокремити навчання моделі від прямого доступу до необроблених навчальних даних, що дозволяє використовувати величезні обсяги даних, які зберігаються на вузлах. Наведемо загальний опис процесу федеративного навчання. Припустимо, що модель, яка навчається, є нейронною мережею, а $f_i(w)$ є функцією втрат прогнозу в прикладі (x_i, y_i) з параметром w . Також припустимо, що існує K користувачів, якими розділені дані, P_k – це множина індексів точок даних клієнта k , а $n_k = |P_k|$. Тоді мінімізована цільова функція може бути виражена як

$$f(w) = \sum_{k=1}^K \frac{n_k}{n} F_k(w), \quad (6)$$

де

$$F_k(w) = \frac{1}{n_k} \sum_{i \in P_k} f_i(w). \quad (7)$$

Нехай C буде часткою вузлів, які вибираються у кожному раунді для обчислення оновлень та градієнтів функції втрат. Якщо $C = 1$, дані у всіх вузлах використовуються для обчислення повного (нестохастичного) градієнтного спуску. Звичайна реалізація федеративного навчання вибирає t випадкових пристроїв у кожному раунді. Центральний сервер надсилає кожному вузлу параметр мережі W_t ; потім кожен користувач обчислює $g_k = \nabla F_k(w_t)$, який є середнім градієнтом його локальних даних у поточній моделі W_t , а потім оновлює параметр $w_t^k \leftarrow (w_t^k - a g_k)$ (де a – швидкість навчання). Цей крок повторюється E разів на пристрої користувачів, щоб гарантувати відправлення найбільш надійного w_t^k назад на центральний сервер.

Потім центральний сервер об'єднує ці w_t^k та застосовує оновлення $w_{t+1} \leftarrow \sum_{k=1}^K \frac{n_k}{n} w_t^k$. Обсяг обчислень визначається трьома ключовими параметрами: C – частка вузлів, що беруть участь у обчисленнях у кожному раунді; E – кількість проходів, що навчаються, кожен клієнт виконує над своїм локальним набором даних у кожному раунді, і B – розмір локального міні-пакета, що використовується для оновлень клієнта. Якщо $B = \infty$ повний локальний набір даних розглядається як міні-пакет. Для користувача з n_k локальними прикладами на кожен раунд буде виконуватися $u_k = E \frac{n_k}{B}$ локальних оновлень.

Федеративне навчання дає низку переваг, включаючи такі: для навчання моделі можна використовувати великий обсяг реальних даних, оскільки вузлів багато і кожен вузол містить певний обсяг даних, агрегування всіх даних збільшує можливість оптимального навчання моделі; навчання виконується на вузлах децентралізовано, що знижує обчислювальне навантаження на центральний сервер; дотримуються вимоги до конфіденційності [4], оскільки користувачі завантажують на сервер лише оновлення параметрів моделі, а не власні дані.

З іншого боку, є й недоліки: центральний сервер все ж таки потребує певної довіри, оскільки процес перевірки оновлень моделі, надісланих користувачем, іноді може призводити до отримання деякої інформації про користувача; вартість зв'язку є суттєвою проблемою, оскільки ресурси зв'язку споживаються двічі на користувача: один раз для надсилання параметрів користувачу та вдруге при поверненні оновлень на сервер. Випадковий характер бездротового зв'язку робить такі оновлення досить складними; додаткові труднощі пов'язані з тим, що навчальні дані не беруться з незалежних і однаково розподілених джерел, оскільки кожен має свій власний набір даних, який може представляти розподіл популяції. Окремі користувачі також мають різні обсяги локальних навчальних даних, і ці відмінності можуть вплинути на збіжність алгоритму навчання; децентралізоване навчання складніше централізованого з точки зору тривалості та налаштування. Тому необхідно заздалегідь ретельно вибирати значення гіперпараметрів та архітектуру нейронної мережі; ефективність федеративного навчання нижча, ніж у централізованого методу.

При навчанні з підкріпленням [2] агент прагне досягти оптимальної поведінки у присутності невизначеності шляхом взаємодії з навколишнім середовищем, що зазвичай моделюється як марківський процес прийняття рішень. З розвитком глибокого навчання було показано, що навчання з підкріпленням забезпечує максимальну продуктивність у таких галузях, як настільні ігри, автономне водіння та робототехніка [1–3]. Огляд останніх досягнень у галузі глибокого навчання з підкріпленням показав, що у більшості програм агент вчиться реагувати на невизначене середовище або на одного суперника, який реагує у відповідь. Однак у багатьох важливих додатках один з одним взаємодіють багато агентів; деякі з них можуть бути пристроями, що реалізують однакові або різні стратегії для прийняття рішень щодо своїх дій. MARL має потенціал для систематичного аналізу середовища за допомогою стратегічно взаємодіючих агентів. Вивчення MARL поєднує у собі навчання з підкріпленням та методи MDP з теорією ігор, особливо з розділом теорії ігор, відомим як ігри середнього поля [1]. Він прагне надати алгоритми, що сприяють вивченню стабільних політик найкращого реагування в багатоагентній системі з достатньою кількістю

агентів, що залишається серйозною проблемою в більшості випадків, оскільки зі збільшенням кількості агентів зростає складність [2].

Складність поширення класичних алгоритмів навчання (таких як Q-навчання з підкріпленням, адаптивний евристичний критик або багаторукий бандит з мінімізацією жалю) для сценаріїв з багатьма користувачами залежить від балансу, який необхідно підтримувати між використанням інформації, отриманої під час навчання, і адекватним визначенням області пошуку. Наприклад, MARL середнього поля може бути дуже ефективним при великій кількості пристроїв, що взаємодіють.

Своєчасна та економічна обробка сигналів та інформації у мережах радіодоступу потребує використання просторово-часових залежностей між мережевими змінними, які виникають у декількох просторово-часових областях, наприклад: області активації користувачів, які включають пристрої МТС/ІоТ, які повідомляють/реагують на корельовані події; області каналів, коли певні користувачі мають схожі характеристики розповсюдження; області контенту даних, коли користувачі у соціальній структурі поділяють чи запитують однаковий контент. Ці залежності відкривають можливості використання приросту продуктивності в бездротових мережах. Тому вивчення залежностей між мережевими змінними має важливе значення для надання розширеної інформації та алгоритмів обробки сигналів для покращеного радіодоступу.

Для отримання масштабованих рішень використовують наближені методи виведення (такі як передача повідомлень) та їх розподілені (багатопроцесорні) версії. Передача повідомлень і наближена передача повідомлень нещодавно продемонстрували масштабовану продуктивність в узагальнених зворотних лінійних задачах і будуть відправною точкою для методів, що застосовуються тут. Існуючі рішення для статичних сценаріїв, які не залежать від часу, будуть розширені для врахування мінливості за часом. Для цього розглянемо типові теоретичні інструменти. Байєсівські мережі можна визначити як окремих випадок у більш загальному класі, відомому як графова модель, в якій вузли представляють випадкові величини, а відсутність дуг – припущення про умовну незалежність між змінними. Якщо розглядати граф загалом, умовні ймовірності, структуру BN і спільний розподіл ймовірностей можна використовувати визначення граничної ймовірності чи правдоподібності кожного вузла. Ця процедура відома як маргіналізація. Розрахунок ступеня довіри у BN виконується щоразу, коли змінюється одна з цих граничних ймовірностей. Ефект спостереження поширюється по мережі, і на кожному кроці поширення оновлюються ймовірності різних вузлів. Відповідно до [3], у простих мережах гранична ймовірність, або правдоподібність кожного стану, може бути обчислена на основі знання спільних розподілів згідно з теоремою Байєса.

Більшість подій у нашому повсякденному житті не виявляються в конкретний момент часу і можуть бути описані за допомогою кількох станів спостережень, які дозволяють говорити про одну завершену кінцеву подію. Модель динамічної байєсівської мережі (DBN) описує систему, яка динамічно змінюється чи розвивається з часом. Ця модель дозволяє користувачам постійно відстежувати та оновлювати систему і навіть прогнозувати її поведінку. DBN зазвичай визначається як окремих випадок однозв'язної BN, спеціально призначений для моделювання часових рядів, як зазначено в [4].

Прихована марківська модель (HMM) – це стохастичний кінцевий автомат, у якому кожен стан генерує (випромінює) спостереження. Будемо використовувати X_t для позначення прихованого стану та Y_t для позначення спостереження. Якщо є K можливих станів, тоді $X_t \in \{1, K\}$. Параметри моделі включають у собі розподіл вихідного стану, модель переходу та модель спостереження. Модель переходу зазвичай характеризується умовним за поліноміальним розподілом $A(i, j) = P(X_t = j | X_{t-1} = i)$, де A – стохастична матриця, яка часто розріджена і її структура зазвичай зображується у вигляді графа, де вузли представляють стани, а стрілки-допустимі переходи (тобто переходи з ненульовою ймовірністю).

Технічні характеристики DBN можна розділити на три категорії: виведення, декодування послідовності, навчання. Навіть експертні знання не можуть запропонувати рішення для деяких умовних відношень у певних галузях. У таких обставинах необхідно вивчити ці конкретні розподіли ймовірностей. Цей процес навчання складний і ґрунтується на алгоритмі максимізації очікування або загальної максимізації очікування (GEM).

У мережах 6G існує безліч потенційних програм для DBN. Наприклад, вивчені залежності між мережевими змінними можуть бути використані для потенційного збільшення продуктивності в різних бездротових послугах. Зокрема, вивчена структура, що змінюється в часі, може використовуватися для динамічної кластеризації користувачів або мережі (зазвичай масивна MIMO без стільників) в різних областях (канал, активність і контент) з прямим впливом на додатки радіодоступу. Яскравим прикладом є кореляційна структура бездротового каналу, що змінюється в часі, яка, якщо її вивчити, може бути використана для підвищення продуктивності RAN.

Очікується величезний приріст продуктивності щодо масового MIMO, оскільки знання структури каналу (зокрема, каналу MIMO) надасть можливість динамічно кластеризувати користувачів RAN на основі умов їх каналу. Структура каналу та кластеризація користувачів полегшують надання схем оцінки каналу з меншими витратами за рахунок зменшення кількості ресурсів каналу для навчання, так і кількості зворотного зв'язку, пов'язаної з оцінками каналу. Байєсівська структура буде надзвичайно ефективною у цьому сценарії, оскільки вона дає переконання щодо якості задіяних оцінок. Ці переконання можна оцінити

як локально на стороні користувача та на границі мережі, так і глобально на центральному сервері та макробазовій станції, щоб полегшити прийняття рішень щодо оцінки каналу та декодування даних. У контексті масових MIMO, розподілених MIMO або безсотових мереж цей підхід призведе до нових схем оцінки каналу та зворотного зв'язку. Зокрема, динамічна кластеризація користувачів впливатиме на структуру та довжину пілотних послідовностей, що використовуються для навчання (як у висхідній, так і в низхідній лінії зв'язку) стільникової системи, в якій базові станції оснащені великою кількістю антен. Це ефективно знизить накладні витрати на навчання, вивільнивши ресурси каналу передачі даних. Зокрема, структура зворотного зв'язку CSI може бути оптимізована на основі кластеризації користувачів та м'якої інформації (переконань), що виводиться процедурою байєсівського виведення.

Крім того, байєсівська структура поєднує виявлення активності користувачів, включаючи модель статистики активації користувачів (яку також можна вивчити). Вона поширюється на неадаптивні та адаптивні методи ймовірнісного групового тестування, щоб використати залежності між користувачами та розподілу ймовірностей, яким вони відповідають. Це особливо актуально у масових сценаріях MTC/LoT, де питання оцінки каналу та виявлення активності користувача мають вирішуватися спільно, щоб зменшити як службові дані, так і час очікування, що пов'язані з процедурою довільного доступу. Зокрема, у додатках з масовим підключенням з двофазною передачею (початковий доступ з подальшою передачею даних) байєсівська структура оцінює оптимальну кількість ресурсів, виділених для початкового доступу (перша фаза), порівняно з ресурсами, виділеними для передачі даних (друга фаза), з негайним перерозподілом ресурсів на етапі передачі. Загалом, очікується, що в переважаних системах, де кількість активних користувачів набагато перевищує кількість антен на базовій станції, планування користувачів за допомогою байєсівського додатку може значно покращити загальну ефективність використання спектру. Це вплине на структури як планових, так і безгрантових (GF) схем, які орієнтовані на додатки MTC/LoT з передачею малих пакетів та об'єднують початковий доступ та передачу даних.

Байєсівський підхід також може застосовуватися для локалізації та прогнозування траєкторії. Крім того, розподілене прогнозування станів каналів та розташування користувачів розглядається як ключовий компонент при розробці надійних систем бездротового зв'язку. Наприклад, прогнозуючи (короткострокове) розташування користувачів або еволюцію їх кутового спектру потужності (тобто функцію, що показує середню енергію на куту в одиницю в антенній решітці), проєктувальники отримують корисну інформацію про попереднє кодування навчальних символів, щоб, спираючись на один і той же пілотний сигнал можна було отримати інформацію про стан каналу для кількох користувачів.

Робота в цій галузі, що поєднує хвильову фізику з теорією інформації, має довгу історію, що сягає витоків теорії інформації [5] і, зокрема, до новаторських робіт по оптичним сигналам та інформації [6]. Для позначення кількості ефективних вимірів комунікації було запроваджено поняття ступенів свободи (DoF). Методики визначення числа ступенів свободи з використанням хвильової теорії були розроблені ще в 1960-х роках, і з того часу подальший прогрес у цій галузі був дуже нерівномірним.

Пропускна здатність каналу визначається як максимальна взаємна інформація:

$$C = \max_{p(x)} \{I(x, y)\}, \quad (8)$$

де x і y – вектори T_x та R_x відповідно. Щоб врахувати вплив законів електромагнетизму на пропускну здатність каналу, [4] визначається просторова пропускна здатність S як максимальна взаємна інформація між векторами T_x та R_x , а також інформація про канал (за умови, що ідеальна інформація про стан каналу відома у R_x):

$$S = \max_{p(x), E} \{I(x, \{y, G(E)\})\}. \quad (9)$$

Обмеження:

$$\langle x + x \rangle \leq P_T, \nabla^2 E - \frac{1}{c^2} \frac{\partial E}{\partial t^2} = 0, E = E_0, \forall \{r, t\} \in B \quad (10)$$

де E – електричне поле, задіяне при передачі даних, B – гранична умова (залежно від середовища розсіювання), G – матриця каналу. Кількість ступенів свободи електромагнітного поля необхідно для розуміння фізичних обмежень бездротових (випромінюючих) систем зв'язку.

Як показано на рис. 1 узагальнений бездротовий канал складається з масиву T_x , каналу поширення (середовища) і масиву R_x . Ґратки T_x і R_x впливають, принаймні, на діаграму спрямованості і взаємний вплив каналів. Складний узагальнений бездротовий канал $G(E)$ зазвичай характеризується як згортка векторів керування решіткою та багатопробових фізичних каналів поширення:

$$G(E) = H = f(\{\varphi_n, \theta_n\}) = \sum_n h_n a_{\theta_n} a_{\varphi_n}^H \quad (11)$$

де n – кількість багатопробових поширень, φ_n і θ_n – кут приходу (AoA) і кут виходу (AoD) хвилі фізичних каналів поширення відповідно, a_{θ} і a_{φ} – керуючі вектори передавальної та приймальної решіток, а h_n – реакція на вплив i -го фізичного каналу з багатопробовим поширенням.



Рис. 1. Схема узагальненого радіоканалу передавання даних

Потенційні технічні дослідження, спрямовані на збільшення кількості ступенів свободи узагальненого бездротового каналу $G(E)$, можна розділити на три категорії: (1) фізичний канал поширення, (2) діаграма спрямованості антенної решітки та взаємний вплив, (3) електромагнітні фізичні характеристики. В епоху 6G нові тенденції в галузі антенних решіток і каналних середовищ спонукають нас знаходити потужніші інструменти аналізу електромагнітних явищ, щоб впоратися зі складністю електромагнітного середовища, що породжується надспрямованими антенними ґратками, ELAA та інтелектуальними метаповерхнями.

З розвитком 6G починають з'являтися різні бездротові технології, які можуть вплинути на розвиток теорії електромагнітної інформації. До них відносяться: LIS, RIS, цифровий керований розсіювач, орбітальний кутовий момент, голографічні MIMO, обертання часу, зв'язок поверхневих хвиль, надмасивні MIMO та ELAA.

У бездротовому зв'язку сигнали, що передаються зазвичай досягають приймача декількома шляхами через відображення від об'єктів (наприклад, будівель). Припустимо, що $h(t)$ – сигнал, що передається, $z(t)$ – характеристика каналу, а d_i і t_i – комплексна амплітуда і затримка в i -му тракті; тоді отриманий сигнал у часовій області можна відобразити наступним чином:

$$x(t) = z(t) * h(t) = \sum_{i=1}^r d_i h(t - t_i), \quad (12)$$

де r – кількість шляхів, які надалі називатимемо модами (mode). Використовуючи перетворення Фур'є, можна представити сигнал у спектральній області наступним чином:

$$\hat{x}(f) = \hat{z}(f) * \hat{h}(f) = \sum_{i=1}^r d_i \hat{h}(f) e^{j2\pi f t_i}. \quad (13)$$

Оскільки переданий сигнал $\hat{h}(f)$ відомий априорі, дані можуть бути виражені як

$$\frac{\hat{x}(f)}{\hat{z}(f)} = \sum_{i=1}^r d_i e^{j2\pi f t_i} \quad \forall d : \hat{h}(f) \neq 0 \quad (14)$$

В результаті, можна отримати класичну модель оцінки параметрів теорії надвисокої роздільної здатності, сумою сигналів r мод:

$$x[t] = \sum_{i=1}^r d_i \psi(t; f_i) \quad t \in Z \quad (15)$$

де d_i - амплітуда, f_i - частота, ψ - (відома) модельна функція (наприклад, $\psi(t; f_i) = e^{j2\pi f_i t}$), а r - кількість мод або порядок моделі. Наша мета – оцінити $2r$ невідомих параметрів $\{d_i\}$ і $\{f_i\}$. Першою широко задіяною теорією роздільної здатності була теорема вибірки Шенона-Найквіста [5], яка вимагає, щоб частота дискретизації щонайменше вдвічі перевищувала максимальну частоту вихідної інформації. Цей критерій відомий як частота дискретизації Найквіста та гарантує ідентичність та цілісність відновленої інформації.

У разі ширококутового сигналу рівномірна роздільна здатність дає перевагу одним частинам, але погіршує інші. Щоб вирішити цю проблему, спочатку використовували віконне перетворення Фур'є, а потім і вейвлети для реалізації множинної роздільної здатності. Якщо ми перетворимо вейвлет-сигнал назад у вихідний навколишній простір (за допомогою декодера), цілком імовірно, що роздільна здатність насправді в загальному випадку не буде однорідною. JPEG-2000 використовує вейвлети для стиснення зображень. Деякі дослідники навіть запропонували замінити OFDM вейвлет-перетворенням для ширококутових сигналів.

Теорія надвисокої роздільної здатності поєднує як неоднорідну роздільну здатність, так і неоднорідну вибірку [6] і може використовуватися в багатьох областях технології 6G.

Системи 6G із широкою смугою частот будуть створювати проблеми для динамічного квантування, а дотримання критерію дискретизації Найквіста призведе до величезного енергоспоживання. Якщо вихідна

інформація є розрідженою за своєю природою, то стає можливою нерівномірна вибірка з низьким енергоспоживанням для зниження енергоспоживання. Теорія надвисокої роздільної здатності може вплинути на напрямки розвитку багатьох технологій, включаючи алгоритми локалізації, стислу вибірку та алгоритми бездротової візуалізації.

Висновки з даного дослідження і перспективи подальших розвідок у даному напрямі

Розглянуто особливості використання машинного навчання в телекомунікаційних мережах та здійснено детальний опис основ теорії штучного інтелекту. Зокрема визначено характер впливу DBN на розвитку багатьох технологій, включаючи виявлення активності користувача, оцінку каналу та відстеження мобільності. Досліджено деякі аспекти бездротового зв'язку та будови антен, які впливають на перетині добре відомих областей електромагнітної теорії Максвелла та теорії інформації Шенона. Зокрема обґрунтовано можливість збільшення кількості ступенів свободи узагальненого бездротового каналу $G(E)$ у розрізі фізичного каналу поширення, діаграми спрямованості антенної решітки та взаємного впливу, електромагнітних фізичних характеристик. Також досліджено особливості виникнення та розвитку багатьох технологій у тандемі з теорією семантичної комунікації, таких як спільне кодування каналу джерела та стиснення джерела у складі мережі 6G. Проаналізовано вплив теорії надвисокої роздільної здатності на напрямки розвитку багатьох технологій, включаючи алгоритми локалізації, стислу вибірку та алгоритми бездротової візуалізації.

Література

1. Pizzo A., Marzetta T. L., and Sanguinetti L. Degrees of freedom of holographic MIMO channels, in Proc. 2020 IEEE 21st International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). IEEE, 2020, pp. 1–5.
2. Basar E., Di Renzo M., De Rosny J., Debbah M., Alouini M.-S., and Zhang R. Wireless communications through reconfigurable intelligent surfaces, IEEE Access, vol. 7, pp. 116. 753–116 773, 2019.
3. Wu H., Bai G. D., Liu S., Li L., Wan X., Cheng Q., and Cui T. J. Information theory of metasurfaces, National Science Review, vol. 7, no. 3, pp. 561– 571, 2020.
4. Бортник Г.Г., Васильківський М.В., Челоян В.А. Спектральний метод оцінювання джерела в телекомунікаційних системах. Вісник Вінницького політехнічного інституту, 2010, № 2, С. 109-114.
5. Бортник Г.Г., Васильківський М.В., Кичак В.М. Методи та засоби підвищення ефективності оцінювання фазового дрижання сигналів у телекомунікаційних системах : монографія. Вінниця : ВНТУ, 2015. 140 с.
6. Бортник Г.Г., Васильківський М.В., Стальченко О.В. Пристрій аналого-цифрового перетворення високочастотних сигналів. Вимірювальна та обчислювальна техніка в технологічних процесах. 2013. № 2. С. 82–85.

References

1. Pizzo A., Marzetta T. L., and Sanguinetti L. Degrees of freedom of holographic MIMO channels, in Proc. 2020 IEEE 21st International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). IEEE, 2020, pp. 1–5.
2. Basar E., Di Renzo M., De Rosny J., Debbah M., Alouini M.-S., and Zhang R. Wireless communications through reconfigurable intelligent surfaces, IEEE Access, vol. 7, pp. 116. 753–116 773, 2019.
3. Wu H., Bai G. D., Liu S., Li L., Wan X., Cheng Q., Cui T. J. Information theory of metasurfaces, National Science Review, vol. 7, no. 3, pp. 561– 571, 2020.
4. Bortnyk G.G., Vasylykivskyi M.V., Cheloyan V.A. Spektral'nyy metod otsinyuvannya dzyheru v telekomunikatsiynyykh systemakh. Visnyk Vinnyts'koho politekhnichnoho instytutu, 2010, № 2, S. 109-114.
5. Bortnyk G.G., Vasylykivskyi M.V., Kychak V.M. Metody ta zasoby pidvyshchennya efektyvnosti otsinyuvannya fazovoho dryzhannya syhnaliv u telekomunikatsiynyykh systemakh: Monohrafiya. Vinnytsya: VNTU, 2015. 140 s.
6. Bortnyk G.G., Vasylykivskyi M.V., Stalchenko O.V. Device for analog-digital conversion of high-frequency signals. Measuring and computing equipment in technological processes. 2013, No. 2. P. 82–85.