

УДК 004.94:621.39

DOI <https://doi.org/10.32782/2663-5941/2026.3.2/14>

Морщавка С.В.

<https://orcid.org/0000-0002-6793-8728>

Національний університет «Запорізька політехніка»

Бугрова Т.І.

<https://orcid.org/0000-0003-1701-9771>

Національний університет «Запорізька політехніка»

Чорнобородов М.П.

<https://orcid.org/0000-0003-1230-9374>

Національний університет «Запорізька політехніка»

Логачова Л.М.

<https://orcid.org/0000-0003-2366-9754>

Національний університет «Запорізька політехніка»

Самойлик С.С.

<https://orcid.org/0000-0003-1308-4744>

Національний університет «Запорізька політехніка»

МЕТОДИ ПРОГНОЗУВАННЯ ПОКРИТТЯ РАДІОМЕРЕЖ З ЗАСТОСУВАННЯМ ГЛИБОКОГО НАВЧАННЯ ТА ДЕКОМПОЗИЦІЙНОГО ПІДХОДУ НА БАЗІ КЛІТИННИХ АВТОМАТІВ

У статті запропоновано гнучкий та обчислювально ефективний метод прогнозування карт покриття радіосигналами приміщень та ділянок на основі двовимірного плану, що поєднує локальне нейромережеве моделювання з ітеративним механізмом поширення сигналу, організованим за принципом клітинного автомата.

У цьому підході використано просторову декомпозицію планів приміщень, для фрагментів яких незалежно навчаються дві нейронні мережі: одна для розподілу сигналу у внутрішній зоні фрагмента; інша для визначення значення сигналу на двох невідомих бічних межах за двома відомими протилежними. Додатково для визначення сигналів протилежної межі застосовано метод конусного оцінювання на основі спрощеної апроксимації принципу Гюйгенса, у якому результативне значення є зваженою сумою вкладень точок джерел вхідної межі з урахуванням кутового відхилення та загасання сигналу на шляху через конструктивні елементи. Цей підхід дозволяє отримувати плавний градієнт тіні за частковими перешкодами та усуває артефакти прямолінійного трасування. Завдяки ж декомпозиції навчання виконується на значно більшій кількості зразків при обмеженій кількості повних планів, що суттєво знижує вимоги до навчальних даних.

Розширення зони розрахунку за планом, організовано у вигляді хвильового фронту від фрагмента з передавачем, коли кожен опрацьований фрагмент передає граничні умови своїм сусідам, які стоять наступними елементами черги. За рахунок багатопрохідної релаксації при додаткових проходах, між якими використовують згладжування сигнального поля з частковим оновленням граничних значень, забезпечується поступове вирівнювання неоднорідностей на межах фрагментів.

Порівняння з еталонними картами, отриманими засобами детерміністичного променевого трасування, підтверджує коректну передачу ефектів загасання та утворення радіотіні при проходженні сигналу через конструктивні будівельні елементи.

Ключові слова: радіомережа, глибоке навчання, клітинний автомат, глибока нейронна мережа, ітеративна декомпозиція, сигнальна карта.



Постановка проблеми. Прогнозування рівня сигналу та побудова карт покриття бездротових мереж є одними з ключових завдань при проектуванні та оптимізації сучасних систем зв'язку – Wi-Fi, LTE та мереж п'ятого покоління. Традиційні емпіричні моделі (Okumura–Hata, COST-231) забезпечують прийнятну точність лише у відносно однорідних середовищах, детерміністичне трасування променів вимагає повної тривимірної моделі середовища та значних обчислювальних ресурсів, методи глибокого навчання здатні апроксимувати складні залежності, але більшість наявних підходів навчаються та застосовуються до повних планів приміщень, що потребує великих навчальних вибірок і не забезпечує масштабованості до довільних розмірів об'єктів. Тож розробка підходу до прогнозування покриття радіомереж, який поєднує методи глибокого навчання, що використовуються локально, з декомпозиційною моделлю, дозволить врахувати просторову структуру середовища та взаємодію між її елементами та набутти властивості масштабування одночасно з універсальністю та точністю сучасних методів глибокого навчання.

Аналіз останніх досліджень і публікацій. З розвитком методів машинного навчання з'явилася можливість застосування глибоких нейронних мереж для прогнозування радіопокриття [1]. Одним із найбільш відомих підходів є модель RadioUNet, запропонована у роботі [2]. У цій моделі використовується згортоква нейронна мережа типу U-Net для оцінювання втрат сигналу між передавачем та будь-якою точкою на площині. Автори показали, що така модель здатна навчатися на даних фізичного моделювання і забезпечує результати, близькі до точних електромагнітних розрахунків, але з набагато меншою обчислювальною складністю.

Метод RadioUNet став основою для подальших досліджень у галузі прогнозування карт покриття. У роботах [3–5] було показано, що глибокі нейронні мережі можуть ефективно враховувати складну структуру міського середовища, включаючи будівлі, вулиці та інші перешкоди. Це дозволяє значно підвищити точність прогнозування рівня сигналу порівняно з традиційними статистичними моделями.

Інший напрям досліджень пов'язаний із використанням глибокого навчання для оцінювання параметрів радіосигналу, таких як рівень прийнятого сигналу (RSSI), втрати на поширення та просторовий розподіл потужності сигналу. У роботах [6,7] запропоновано моделі на основі повнозгорткових нейронних мереж (FCNN) для

прогнозування карт рівня сигналу у приміщеннях та міських середовищах. Такі моделі дозволяють будувати двовимірні карти потужності сигналу з високою просторовою роздільною здатністю.

У роботі [8] запропоновано модель на основі генеративних змагальних мереж (GAN) для інтерполяції вимірювань сигналу та побудови радіокарт на основі обмеженої кількості вимірювань. Запропонований підхід дозволяє формувати гладкі та точні радіокарти навіть при нерівномірному розташуванні сенсорів.

Іншим перспективним напрямком є гібридні підходи [9], що поєднують фізичні моделі поширення радіохвиль і методи машинного навчання. У таких підходах дані, отримані за допомогою симуляцій на основі моделей трасування променів, використовуються для попереднього навчання нейронної мережі, після чого модель адаптується до реального середовища за допомогою обмеженої кількості вимірювань. Такий підхід дозволяє зменшити обсяг необхідних експериментальних даних та підвищити узагальнювальну здатність моделі.

Важливим етапом розвитку цієї галузі став міжнародний конкурс Pathloss Radio Map Prediction Challenge, результати якого узагальнено у роботі [10]. У цьому дослідженні було проведено порівняльний аналіз сучасних методів прогнозування карт радіопокриття, включаючи моделі на основі CNN, GAN та трансформерів. Результати показали, що методи глибокого навчання здатні забезпечити високу точність прогнозування при значно меншій обчислювальній складності порівняно з методами трасування променів.

Аналіз сучасних досліджень показує, що використання глибокого навчання значно підвищує точність прогнозування покриття радіомереж. Нейронні мережі здатні враховувати складні просторові залежності між параметрами середовища та характеристиками сигналу, що дозволяє отримувати більш точні результати порівняно з традиційними моделями. Разом з тим такі підходи мають ряд обмежень. По-перше, вони потребують значних обсягів навчальних даних. По-друге, моделі глибокого навчання можуть бути чутливими до змін середовища, що потребує додаткових механізмів адаптації.

У зв'язку з цим перспективним напрямом досліджень є поєднання методів глибокого навчання з математичними моделями просторових процесів, зокрема з методами на основі клітинних автоматів. Такий підхід дозволяє поєднати високу точність нейронних мереж із ефективним моделюванням просторової структури радіомереж.

Постановка завдання. Беручи до уваги обмеження класичних підходів до прогнозування радіопокриття, а також недоліки сучасних нейромережових моделей, що потребують значних обчислювальних ресурсів та великого обсягу навчальних даних, у даній роботі пропонується альтернативний підхід до локального моделювання радіополя. Його основна ідея полягає в уявленні плану у вигляді двовимірної дискретної сітки

$$P = \{p_{i,j}\}, \quad i = 1, N, \quad j = 1, M,$$

де кожна комірка $p_{i,j}$ відповідає локальній області певного розміру.

Кожна комірка характеризується набором ознак

$$x_{i,j} = (m_{i,j}, a_{i,j}, d_{i,j}, w_{i,j}, \dots),$$

де $m_{i,j}$ – тип матеріалу (бетон, цегла, дерево, скло тощо);

$a_{i,j}$ – наявність точки доступу;

$d_{i,j}$ – відстань до передавача;

$w_{i,j}$ – наявність дверей або вікон.

Задача полягає у знаходженні функції

$$f_{\theta}(X) \rightarrow R,$$

де X – локальний фрагмент плану розміром $k \times k$ комірок,

R – прогнозований рівень сигналу (RSSI).

Вказана функція є предметом задачі оптимізації на базі функції втрат, наприклад такої:

$$L = \frac{1}{N} \sum (RSSI_{pred} - RSSI_{true})^2$$

Після отримання прогнозів для всіх локальних областей формується глобальна карта покриття

$$C = \{r_{i,j}\},$$

яка відображає просторовий розподіл рівня сигналу у приміщенні.

При цьому ключовим завданням є розробка алгоритму декомпозиції глобальної карти на локальні області, який дозволить локально розрахувати рівень сигналу в кожній з них, використовуючи тільки сигнали на межах суміжних фрагментів, та здійснити подальше зшивання прогнозованих результатів всіх фрагментів. Критерієм правильності є відтворення розподілу сигналів у межах всього плану. Вирішити це завдання пропонується через поступове поширення передбачення сигналу від джерела випромінювання у навколишній простір з використанням локальної нейромережової моделі, що враховує параметри середовища та значення сигналу на межах раніше обчислених областей.

Метою статті є верифікація можливостей реалізації гнучкого та ефективного з обчислювальної точки зору методу прогнозування карт покриття радіосигналами приміщень та ділянок на основі двовимірного плану. Підхід має поєднати локальне нейромережеве моделювання з ітеративним механізмом поширення сигналу, яке організується за принципом клітинного автомату

Виклад основного матеріалу. На відміну від традиційних підходів, де простір одразу дискретизується на регулярну піксельну сітку з подальшим незалежним розрахунком кожної точки або комірки, у запропонованому підході декомпозиція простору на фрагменти виконується динамічно по мірі поширення хвилі передбачень сигналів. Ці сигнали розраховуються локально та ітеративно для отримання усталених значень.

Початковим елементом розрахунку є квадратна область, у центрі якої розташовано передавач або точку доступу. Для цієї області формується початкове передбачення рівня сигналу на основі параметрів передавача (потужність, частота, тип антени) та локальної інформації про геометрію середовища (стіни, матеріали, перешкоди, якщо вони там є). Цей початковий стан є базою для подальшого поширення моделі.

На наступному етапі розрахунок розширюється на чотири сусідні комірки – вгору, вниз, ліворуч та праворуч від початкової комірки. Для кожної з них передбачення виконується нейромережевою моделлю, яка використовує в якості вхідних параметрів не лише локальні характеристики середовища, але й значення сигналу на спільній межі із вже обчисленою коміркою. Таким чином, інформація про рівень сигналу поступово передається між сусідніми комірками, що дозволяє моделювати природний процес затухання та дифракції електромагнітної хвилі в середовищі її поширення.

Подальший розвиток розрахунку відбувається ітеративно: кожна нова область, для якої отримано прогноз, породжує розрахунок для своїх сусідніх областей, які не були обчислені раніше (рис. 1). Фактично формується хвилеподібний фронт обчислення, що поступово розширюється від джерела сигналу до віддалених частин приміщення. При цьому значення сигналу на межах між комірками використовуються в якості граничних умов для нових локальних прогнозів.

Такий механізм нагадує принцип функціонування клітинних автоматів, зокрема класичної гри «Життя» (Game of Life) [11], де стан кожної клітини визначається станами сусідніх клітин.

У даному випадку станом клітини є прогнозований рівень сигналу, а еволюція системи визначається нейромережевою моделлю, що виконує роль локального оператора переходу. На відміну від випадкової або наперед заданої регулярної дискретизації простору, обчислювальна сітка формується поступово, у міру необхідності, що дозволяє концентрувати обчислювальні ресурси в тих областях, де відбуваються суттєві зміни сигналу.

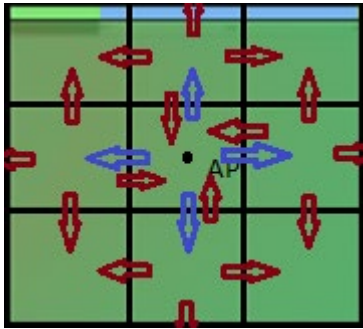


Рис. 1. Напрямки поширення розрахунків на 1-му та 2-му кроці (сині та червоні стрілки, відповідно)

Ітераційний процес релаксації триває доти, доки не буде досягнуто або усталеного розподілу сигналу, або повторення заданої кількості разів. Для прикладу, наведеному на рис. 1, це означатиме, що на третьому кроці повторювати поширення з комірки з точкою доступу до сусідніх комірок не потрібно, якщо тільки перешкода з якогось боку не буде створювати відбиття, яке впливає на розподіл в цій комірці. Після цього сформована карта покриття вважається стабілізованою та може використовуватися для подальшого аналізу, оптимізації розміщення точок доступу або для оцінки якості зв'язку. Для безпосередніх передбачень у кожному локальному фрагменті може бути використана архітектура згорткової нейронної мережі.

Для перевірки запропонованого підходу був розроблений програмний модуль, що реалізує повний цикл: підготовку навчальних даних, навчання нейромережевої моделі та ітеративне поширення сигналу від джерела по всьому плану приміщення. В процесі розробки підхід суттєво вдосконалювався у двох напрямках: поліпшення точності оцінки граничних умов між суміжними ділянками та забезпечення повноцінної релаксації при повторних проходах обчислень.

Навчальні дані формувались на основі набору растрових зображень планів приміщень у форматі BMP, для кожного з яких заздалегідь було розраховано еталонний розподіл рівня сигналу засобами детермінованого трасувального моделювання. Рівень сигналу декодувався за формулою

$(G - R + 255) / 510$, що дозволяє представити його у нормалізованому діапазоні $[0, 1]$ на основі співвідношення зеленого (G) та червоного (R) каналів зображення.

Для кожного плану формувалась маска структурних елементів середовища. Кожному типу конструктивного елемента присвоювалось числове значення у діапазоні від 0 до 1, яке відображає відносний ступінь загасання сигналу. Наприклад, для легких стін обирався коефіцієнт 0,1, натомість, для бетонних стін – рівень коефіцієнта був 0,5 а для металевих елементів він дорівнював 0,8.

Отримані сигнальні карти та маски динамічно нарізались на перекривні фрагменти розміром $n \times 12 \times n \times 12$ пікселів із кроком $n \times 11$ пікселі (рис. 2). Тут n відіграє функцію масштабування – пристосування до реального піксельного масштабу плану без необхідності перенавчання моделей. Такий крок забезпечує точне суміщення граничних рамок сусідніх фрагментів: гранична рамка правого фрагмента шириною n пікселів збігається рівно з граничною рамкою лівого без подвійного перекриття внутрішньої зони. Фрагменти, у яких центральна зона $n \times 10 \times n \times 10$ не містила жодного ненульового значення сигналу, виключались із навчальної вибірки.




Рис. 2. Приклад декомпозиції плану, що використовується для навчання

В кінцевій реалізації використовуються дві спеціалізовані нейромережеві моделі, кожна з яких вирішує окрему задачу. Перша – відповідає за заповнення внутрішньої зони. Вона призначається для передбачення розподілу сигналу всередині фрагмента за умови, що всі чотири граничні межі вже відомі. Для неї кожен навчальний взірєць містить граничні рамки, заповнені еталонними значеннями, а внутрішня зона є зоною прогнозу. Ця модель є основою системи, оскільки описані нижче меха-

нізми визначення граничних умов зрештою зводять будь-який випадок до задачі з чотирма відомими межами. Друга модель відповідає за заповнення бічних меж. Вона призначається для відновлення двох невідомих протилежних меж фрагмента, коли відомі лише дві інші протилежні межі. Вхідний сигнальний канал для неї містить значення лише на відомій парі меж, а функція втрат зосереджена на точності відновлених сторін. Навчання цієї моделі виконується з двома орієнтаціями (горизонтальною та вертикальною) шляхом повороту фрагментів на 90 градусів.

Обидві моделі побудовані за архітектурою згорнутої мережі типу U-Net для фрагментів 36×36 пікселів. (Тут і надалі будемо вважати, що n дорівнює 3. Це значення є достатнім для використаних планів розмірами до 1000 пікселів). Кодувальна частина містить два блоки згорткових шарів з проміжним зменшенням просторового розміру (36×36 → 18×18 → 9×9), що дозволяє охопити рецептивним полем увесь фрагмент. Розшифрувальна частина відновлює розмір через транспоновані згортки з передачею відповідних ознак від кодувальника. Вихідний шар формує передбачений розподіл сигналу. Навчання проводилось оптимізатором Адама з початковою швидкістю навчання 0,001 та планувальником, що поступово знижує швидкість навчання за косинусним законом протягом 80 епох.

Початкові спроби заповнення відсутніх граничних умов шляхом прямолінійного перенесення сигналу вздовж одного променя від відомої межі виявили суттєві артефакти у вигляді чітких прямолінійних тіней за перешкодами та рівномірних «променів» у чотири сторони від передавача. Причина цього полягає в тому, що поширення радіосигналу є явищем хвильовим: сигнал огинає краї перешкод, тінь від асиметрично розташованого конструктивного елемента плавно розмивається в просторі, а не обривається різко.

Для усунення цього недоліку запроваджено конусне оцінювання граничних умов, що апроксимує принцип Гюйгенса: кожна точка відомої межі розглядається як окреме точкове джерело сигналу, що поширюється у широкому конусі. Результуюче значення $\hat{s}(d)$ на відсутній межі є зваженою сумою вкладів від усіх Q точок-джерел активної межі:

$$\hat{s}(d) = \frac{\sum_{q=1}^Q w_q a_q s(q)}{\sum_{q=1}^Q w_q}$$

де $s(q)$ – значення сигналу у точці-джерела q , w_q – кутова вага, a_q – загасання вздовж відповідного променя.

Вага кожного джерела визначається двома факторами. Перший – кутове відхилення від основного напрямку поширення, яке враховується за законом Гауса:

$$w_q = e^{-\frac{l_q^2}{2\sigma^2}}, \quad l_q = \frac{|l_q - l_d|}{r_{qd}},$$

де l_q – нормована бічна відстань між джерелом q та цільовою точкою d , r_{qd} – пряма відстань між ними, σ – параметр ширини конуса.

Завдяки такому зважуванню джерела, які розташовано поблизу основного напрямку поширення, створюють домінуючий внесок, тоді як бічні джерела впливають на результат значно менше.

Другий фактор – загасання a_q вздовж дискретного шляху від точки q до точки d . Загасання розраховується як добуток коефіцієнтів прозорості по кожному пікселю шляху:

$$a_q = \prod_{i=1}^L (1 - m_i),$$

де $m_i \in [0,1]$ – значення маски структурного елемента у i -му пікселі шляху ($m_i = 0$ для вільного простору, $m_i \approx 1$ для суцільної перешкоди), L – довжина шляху в пікселях.

При наявності перешкоди у вигляді суцільної стіни добуток прагне до нуля, що повністю блокує внесок відповідного джерела. Це природним чином формує радіотінь за перешкодою. Для часткових перешкод (вікна, легкі перегородки) добуток залишається ненульовим, що дозволяє отримувати плавний градієнт тіні замість різкого обриву, характерного для прямолінійного трасування.

Така апроксимація дає плавний градієнт тіні в зонах за частковими перешкодами: частина конусу проходить повз перешкоду і створює ненульовий внесок, тоді як промені, що перетинають перешкоду, загасають.

Повний алгоритм встановлення граничних умов перед застосуванням моделі заповнення внутрішньої зони залежить від кількості вже відомих меж фрагмента. Якщо відомі всі чотири межі, модель заповнення внутрішньої зони застосовується безпосередньо. Якщо відомі дві суміжні межі, конусне оцінювання відновлює дві відсутні, після чого застосовується модель заповнення внутрішньої зони. Якщо відома лише одна межа, конусне оцінювання встановлює протилежну межу, після чого модель заповнення бічних меж відновлює дві суміжні, і лише тоді виконується заповнення внутрішньої зони.

Перед початком розрахунку вхідний план розширюється доповненням (відступами) таким чином, щоб будь-яка його точка потрапляла при-

наймні в один фрагмент, а загальний розмір був кратний кроку 33 пікселі. Граничні рамки фрагмента з точкою доступу ініціалізуються значенням 0,75 (що відповідає зеленому кольору на плані) і фіксуються як незмінні.

Розрахунок виконується методом хвильового поширення: від фрагмента з передавачем назовні у чотири сторони (як на рис.1), з поступовим охопленням усього плану. Для кожного нового фрагмента формуються граничні умови описаним вище методом, після чого модель заповнення внутрішньої зони передбачає розподіл сигналу в центральній частині. Вихідні межі фрагмента фіксуються і слугують граничними умовами для сусідніх фрагментів наступного кроку поширення.

Перший прохід хвильового поширення формує початкове глобальне поле покриття. Однак через те, що кожен фрагмент у цьому проході отримує лише обмежену інформацію про сусідів (найчастіше з одного або двох боків), результат містить помітні неоднорідності на межах між фрагментами. Для їх усунення реалізовано багатопрохідну релаксацію за принципом клітинного автомата: після першого проходу виконуються додаткові повні проходи хвилі по всіх фрагментах плану. У кожному наступному проході кожен фрагмент вже має чотири відомі межі (від попереднього проходу), тож застосовується виключно модель заповнення внутрішньої зони з оновленими граничними умовами від сусідів. Кількість додаткових проходів задається параметром глибини релаксації.

Щоб релаксаційні проходи давали реальне уточнення, а не просто відтворювали попередній результат, між кожними двома проходами виконується медіанне згладжування глобального поля покриття. Медіанний фільтр із вікном розміром у один фрагмент (36 пікселів) застосовується до всіх пікселів, де присутній сигнал і відсутні структурні елементи. Значення на зафіксованих пікселях (точка доступу) та у зонах структурних елементів залишаються незмінними. Для решти пікселів (включно з граничними рамками фрагментів) застосовується м'яке змішування: результуюче значення обчислюється як зважена сума $(1 - \alpha)$ від попереднього та α від згладженого. Завдяки цьому граничні умови між проходами поступово вирівнюються, і кожен наступний прохід отримує дещо інші вхідні дані, що й забезпечує справжню релаксацію системи.

Запропонований алгоритм дозволяє отримувати карти покриття для планів довільного розміру без перенавчання моделі. Вся адаптація до розміру приміщення відбувається на рівні меха-

нізму хвильового поширення, в той час, як нейромережеві моделі завжди оперують фрагментами фіксованого розміру 36×36 пікселів для масштабу $n=3$. Зміна масштабного коефіцієнта можлива без перенавчання моделей.

Приклад отриманих результатів наведено на рис.3, де показано початкові дані у вигляді прямокутної кімнати з металевою перегородкою посередині та розташуванням передавача над нею (на плані), а також отриманий результат моделювання запропонованим методом у порівнянні з результатом моделювання за допомогою трасування променів у сторонньому програмному продукті.




Рис. 3. Приклад тестового плану (а) та результатів його прогнозування (б) запропонованим методом та розраховані методом променевого трасування (в)

Результати демонструють узгодженість областей радіотіні, але є дещо відмінними у кількісних оцінках послаблення сигналу, що вимагає подальшої калібрації коефіцієнтів поглинання різних елементів в ході глобальної параметричної оптимізації параметрів.

Висновки. Запропонований підхід має кілька важливих властивостей, які дозволяють покращити процес створення карт покриття радіосигналів, зокрема, полегшити масштабування та підвищити ефективність прогнозування рівня сигналу. Масштабованість досягається тим, що робить моделі глибокого навчання, передусім згорткові нейромережі, придатними для прогнозування у приміщеннях довільного розміру, завдяки використанню локальних фрагментів плану, з яких складається повна картина. Ефективність навчання та використання моделей підвищується внаслідок того, що замість великих планів використовується велика кількість невеликих навчальних вибірок. Це підвищує сумісність із сучасними DL методами (CNN-архітектури) без надмірного ускладнення моделей завдяки використанню методології клітинних автоматів для організації поширення радіосигналів. При цьому локальний характер обчислень дозволяє легко масштабувати алгоритм та реалізувати його на обчислювальних пристроях з обмеженими ресурсами, включаючи вбудовані системи.

Додатковою перевагою запропонованого підходу є можливість адаптивного уточнення карти покриття. Наприклад, у тих областях, де спостерігаються значні градієнти сигналу (поблизу перешкод або меж приміщень), розмір локальних комірок може бути зменшений, що збільшує просторову точність моделі. Натомість, у зонах з плавною зміною сигналу, допускається використання більших за розміром областей, що зменшує загальну кількість обчислень.

Таким чином, запропонований підхід поєднує переваги фізично обґрунтованого моделю-

вання та сучасних методів машинного навчання. Локальна нейромережева модель виступає аналогом оператора поширення електромагнітного поля, тоді як ітераційна схема розповсюдження обчислень забезпечує формування глобальної карти покриття. Така архітектура потенційно дозволяє створювати системи швидкого прогнозування радіопокриття для мереж Wi-Fi, Bluetooth та інших бездротових технологій зв'язку без необхідності виконання складних електродинамічних розрахунків у повному обсязі.

Список літератури:

1. O'Shea T., Hoydis J. An Introduction to Deep Learning for the Physical Layer, in *IEEE Transactions on Cognitive Communications and Networking*, 2017. Vol. 3, no. 4, pp. 563-575, Dec. 2017. doi: 10.1109/TCCN.2017.2758370
2. Levie R., Yapar C., Kutyniok G., Caire G. RadioUNet: Fast Radio Map Estimation With Convolutional Neural Networks. *IEEE Transactions on Wireless Communications*. 2021. Vol. 20, № 9. P. 5698–5711. <https://doi.org/10.48550/arXiv.2105.07158>
3. Tian Y., Yuan S., Chen W., Liu N. RadioNet: Transformer Based Radio Map Prediction Model for Dense Urban Environments. *IEEE Access*. 2021. Vol. 9. P. 79557–79569. doi: 10.1109/ISAP.2021.9753644
4. Yapar C., Levie R., Kutyniok G., Caire G. LocUNet: Fast Urban Positioning Using Radio Maps and Deep Learning. *IEEE International Conference on Communications (ICC)*. 2022. P. 1–6. <https://doi.org/10.48550/arXiv.2202.00738>
5. Sallouha H., Sarkar S., Krijestorac E., Cabric D. Agile Radio Map Prediction Using Deep Learning. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2023. P. 1–5. doi: 10.1109/ICASSP49357.2023.10096546
6. Mismar F. B., Evans B. L., Alkhateeb A. Deep Reinforcement Learning for 5G Networks: Joint Beamforming, Power Control, and Interference Coordination, in *IEEE Transactions on Communications*, 2020. Vol. 68, no. 3, pp. 1581-1592, March 2020, doi: 10.1109/TCOMM.2019.2961332.
7. Pyo C., Sawada H., Matsumura T. A Deep Learning-Based Indoor Radio Estimation Method Driven by 2.4 GHz Ray-Tracing Data in *IEEE Access*, 2023. Vol. 11, pp. 138215-138228, 2023, doi: 10.1109/ACCESS.2023.3340204
8. Sarkar, Sapan & Manshaei, Mohammad Hossein & Krunz, Marwan. RADIANCE: Radio-Frequency Adversarial Deep-learning Inference for Automated Network Coverage Estimation. 2023, doi: 10.48550/arXiv.2308.10584.
9. Thrane J., Zibar D., Christiansen H. L. Model-Aided Deep Learning Method for Path Loss Prediction in Mobile Communication Systems at 2.6 GHz, in *IEEE Access*, 2020. Vol. 8, pp. 7925-7936. doi: 10.1109/ACCESS.2020.2964103.
10. Yapar C., Jaensch F., Levie R., Kutyniok G., Caire G. Overview of the First Pathloss Radio Map Prediction Challenge, in *IEEE Open Journal of Signal Processing*, 2024, vol. 5, pp. 948-963, 2024, doi: 10.1109/OJSP.2024.3419563.
11. Gardner, M. (1970). Mathematical Games: The fantastic combinations of John Conway's new solitaire game «life». *Scientific American*, 1970. № 223, 120-123

Morshchavka S.V., Bugrova T.I., Chornoborodov M.P., Logacheva L.M., Samoilyk S.S. RADIO NETWORK COVERAGE PREDICTION METHODS USING DEEP LEARNING AND DECOMPOSITION APPROACH BASED ON CELLULAR AUTOMATA

The paper proposes an adaptive and computationally efficient method for predicting indoor and outdoor radio signal coverage maps from two-dimensional floor plans. The method combines local neural network modelling with an iterative signal propagation mechanism organized on the principle of a cellular automaton.

The method employs spatial decomposition of floor plans, for whose fragments two neural networks are trained independently: one for reconstructing the signal distribution within the interior zone of a fragment, and another for determining signal values on two unknown lateral boundaries given to two known opposite ones. Additionally, a cone estimation method based on a simplified approximation of the Huygens principle is used to determine signals on the opposite boundary, in which the resulting value is a weighted sum of contributions from source points on the input boundary, accounting for angular deviation and signal attenuation along the path through structural elements. This approach yields a smooth shadow gradient behind partial obstacles and eliminates ray-tracing artefacts. Furthermore, decomposition-based training is performed on a substantially larger number of samples with a limited number of complete floor plans, significantly reducing the requirements for training data.

Propagation of the computation across the floor plan is organized as a wavefront from the transmitter fragment, with each processed fragment passing boundary conditions to its neighbors, which become the next elements in the queue. Multi-pass relaxation over additional passes, between which smoothing of the signal field with partial updating of boundary values is applied, ensures gradual elimination of inhomogeneities at fragment boundaries.

Comparison with reference maps obtained by deterministic ray tracing confirms accurate reproduction of attenuation effects and radio shadow formation as the signal passes through structural building elements.

Keywords: radio network, deep learning, cellular automaton, deep neural network, iterative decomposition, signal map, loss function.

Дата першого надходження статті до видання: 22.03.2026

Дата прийняття статті до друку після рецензування: 18.04.2026

Дата публікації (оприлюднення) статті: 19.05.2026