

Геращенко А.Ю.Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»**Лебедев Д.Ю.**Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

ТЕХНОЛОГІЯ ПРОГНОЗУВАННЯ ПАРАМЕТРІВ БЕЗДРОТОВИХ МЕРЕЖ СТАНДАРТУ 802.11 ДЛЯ АДАПТИВНОЇ ОПТИМІЗАЦІЇ

Стаття присвячена аналізу сучасних методів оптимізації параметрів бездротових мереж стандарту IEEE 802.11 із використанням підходів машинного навчання. Розкрито вплив ключових параметрів мережі, таких як OBSS/PD, пропускна здатність, RSSI та інтерференція, на якість передачі даних. У статті розглянуто існуючі підходи до прогнозування якості сигналу на основі співвідношення сигнал/інтерференція/шум (SINR) із застосуванням алгоритмів штучних нейронних мереж (ANN) та методів адаптивної оптимізації.

З'ясовано, що статичні або емпіричні методи налаштування мереж є недостатньо ефективними в умовах динамічного середовища. Доведено, що використання машинного навчання для прогнозування параметрів мережі дозволяє враховувати змінність середовища передачі даних та забезпечує підвищення продуктивності Wi-Fi. У статті визначено основні недоліки традиційних підходів, зокрема залежність від статичних конфігурацій і низьку адаптивність до змін середовища.

Запропоновано нову систему оптимізації, що використовує нейронну мережу для точного прогнозування SINR та динамічної адаптації параметрів Wi-Fi. Розкрито особливості автоматичної оптимізації, яка підвищує продуктивність мережі, забезпечує стабільність передачі даних та покращує якість обслуговування в реальних умовах. Визначено переваги запропонованого підходу, зокрема зниження впливу інтерференції та підвищення ефективності роботи мережі навіть у складних сценаріях.

У статті сформовано напрями для подальшого вдосконалення, серед яких впровадження багаторівневої оптимізації параметрів, інтеграція енергоефективних рішень та використання новітніх методів машинного навчання. Зроблено висновок, що адаптивна оптимізація мереж Wi-Fi з використанням штучного інтелекту є перспективним напрямом для підвищення продуктивності бездротових мереж стандарту IEEE 802.11.

Ключові слова: Wi-Fi, SINR, нейронна мережа, оптимізація параметрів, машинне навчання, 802.11.

Постановка проблеми. Основною метою оптимізації параметрів бездротових мереж є забезпечення стабільної та високоякісної передачі даних, особливо в умовах динамічних змін середовища. Чим ефективніше налаштовуються параметри мережі у відповідь на ці зміни, тим краще використовуються її ресурси та забезпечується якість обслуговування (QoS). Це підкреслює важливість розробки адаптивних підходів до управління параметрами мережі стандарту 802.11.

На сьогодні існує чимало підходів до оптимізації параметрів Wi-Fi мереж, таких як OBSS/PD, RSSI, interference тощо. Однак, більшість з них базуються на статичних або емпіричних налаштуваннях, які не враховують постійних змін середовища, таких як взаємні перешкоди між пристроями чи зміна розташування користувачів. Це

приводить до недостатньої ефективності мережі та втрати продуктивності.

У межах цього дослідження буде запропоновано новий підхід, що базується на використанні нейронної мережі для прогнозування параметра SINR (Signal-to-Interference-and-Noise Ratio), який є ключовим для оцінки якості каналу передачі даних. На основі отриманих прогнозів реалізується адаптивна оптимізація таких параметрів мережі для підвищення її продуктивності.

Аналіз останніх досліджень і публікацій. Протягом останніх років значна увага дослідників була приділена застосуванню методів машинного навчання (ML) для оптимізації продуктивності Wi-Fi мереж, стандартизованих у рамках IEEE 802.11. Сучасні модифікації стандартів, такі як Wi-Fi 6 (802.11ax) [1] та Wi-Fi 7 (802.11be)

[2], пропонують розширені функціональні можливості, але також ускладнюють налаштування мереж через багатопараметричність. Застосування ML забезпечує ефективне управління цими складними системами, пропонуючи підхід до нелінійної оптимізації мережевих параметрів і покращення продуктивності.

По-перше, основною задачею застосування ML для управління доступом до каналу є мінімізація колізій при спільному доступі до каналів. Зокрема, такі алгоритми, як Q-навчання [3] та Deep Q-Networks [4], дозволяють динамічно адаптувати параметри вікна конфліктів (CW), зменшуючи час очікування та кількість зіткнень. Наприклад, механізми на базі RL, такі як iQRA, показують значне підвищення пропускної здатності в умовах густо розташованих точок доступу, одночасно підтримуючи низькі затримки.

По-друге, ML широко використовується для оптимізації налаштувань фізичного рівня, вибору параметрів модуляції та кодування (MCS), що є ключовими для адаптації швидкості передачі даних до змінних умов мережі. Використання алгоритмів штучних нейронних мереж (ANN) [5] дозволяє швидко передбачати оптимальні параметри, що призводить до підвищення пропускної здатності мережі в мобільних сценаріях. Також для динамічної адаптації значень коротких захисних інтервалів (SGI) [6] використовуються алгоритми онлайн-навчання, що дозволяють враховувати флуктуації сигналу.

По-третє, покращення ефективності агрегації кадрів [7], як-от A-MSDU та A-MPDU, має критичний вплив на баланс між передатною спроможністю і помилками передачі. Методи ML, такі як алгоритми на основі дерев рішень і випадкових лісів, використовуються для визначення оптимального розміру кадру залежно від умов мережі. Це дозволяє зменшити кількість повторних передач та покращити загальну пропускну здатність.

Розглянуті підходи демонструють значні переваги використання ML для покращення продуктивності Wi-Fi мереж. Основними перевагами є адаптивність до змінних умов мережі, здатність до автоматизованої оптимізації параметрів та підвищення загальної ефективності. Недоліками є необхідність великих обчислювальних ресурсів, особливо для навчання складних моделей, та потреба у більш реалістичному моделюванні для врахування мобільності користувачів і багаторівневого управління.

На сучасному етапі досліджень актуальним є створення рішень, які забезпечують інтеграцію

машинного навчання у реальні мережі з урахуванням змін середовища, енергоефективності та вимог до затримок. Це дозволить впровадити адаптивні технології, що підвищують продуктивність Wi-Fi мереж нового покоління.

Постановка завдання. На основі проведеного аналізу визначено ключові параметри, які потребують оптимізації, та сформульовано технічні вимоги до моделі нейромережі:

1. Розробити модель для прогнозування SINR на основі параметрів мережі. Модель повинна враховувати основні фактори, що впливають на якість каналу передачі даних у Wi-Fi мережах, зокрема OBSS/PD, throughput, RSSI, та interference. Використання нейронної мережі дозволить реалізувати точний прогноз SINR у динамічних середовищах.

2. Реалізувати механізм адаптивної оптимізації параметрів Wi-Fi. Після прогнозування SINR модель повинна вибирати найкращі значення параметрів (наприклад, OBSS/PD) для забезпечення максимального SINR.

3. Розробити програмний прототип системи. Прототип повинен містити інтерфейс для введення вхідних параметрів (OBSS/PD, throughput, RSSI тощо) та прогнозування SINR.

Виклад основного матеріалу. Проаналізувавши існуючі підходи до оптимізації параметрів бездротових мереж стандарту 802.11, пропонується інтелектуальна система, що дозволяє ефективно прогнозувати параметри SINR і здійснювати адаптивну оптимізацію мережевих налаштувань. Розроблена система орієнтована на покращення продуктивності Wi-Fi мереж у реальних умовах, враховуючи динамічні зміни середовища. Запропонований підхід базується на використанні нейронних мереж для прогнозування параметрів та алгоритмів адаптивної оптимізації.

Розроблена система забезпечує процес оптимізації параметрів бездротових мереж, включаючи:

- Прогнозування значення SINR на основі вхідних параметрів мережі (OBSS/PD, throughput, interference, RSSI).
- Автоматичне налаштування параметрів мережі для забезпечення максимальної продуктивності.
- Інтеграцію з реальними мережами для роботи в умовах високого навантаження.

Основні етапи роботи системи:

1. Збір даних і формування вхідної інформації. Користувач вводить параметри мережі. Це можуть бути:

- OBSS/PD – поріг виявлення пакетів у перекриваючихся BSS.

- Throughput – пропускна здатність мережі.
- Interference – рівень перешкод між точками доступу.
- RSSI – потужність сигналу, що приймається пристроєм.

Ці дані формують вхідний файл, що перевіряється на коректність і подається на обробку для форматування його у формат, зручний для навчання нейромережі.

2. Прогнозування параметра SINR

На основі вхідних даних нейронна мережа прогнозує значення SINR, використовуючи такі кроки:

- Обробка вхідних параметрів де вхідні дані масштабуються та нормалізуються.
- Прогнозування нейронною мережею, яка складається з трьох прихованих шарів із функціями активації ReLU, що передбачає значення SINR для заданої конфігурації.
- Виведення прогнозованого значення SINR та передача його на наступний етап для аналізу та оптимізації.

3. Адаптивна оптимізація мережевих параметрів

Розроблений алгоритм вибирає найкращу конфігурацію параметрів мережі, яка забезпечує максимальне значення SINR. Процес оптимізації складається з таких кроків:

- Генерується набір можливих конфігурацій параметрів OBSS/PD, RSSI, interference та throughput (рис. 1).

```
# Приклад конфігурацій для оптимізації
sample_configs = pd.DataFrame({
    'OBSS/PD': [-64, -62, -63],
    'throughput': [20, 25, 30],
    'interference': [-70, -80, -90],
    'RSSI': [-60, -55, -50]
})
```

Рис. 1. Приклад конфігурацій для оптимізації

- Кожна конфігурація подається на вхід моделі для прогнозування SINR.
 - Вибирається конфігурація з максимальним прогнозованим SINR.
- ## 4. Виведення результатів і рекомендацій
- Система відображає:
- Обрану конфігурацію параметрів (рис. 2).
 - Графік втрат (loss) під час навчання.

Графік (рис. 3) демонструє динаміку функції втрат (Loss) для навчального (синя лінія) та валідаційного (помаранчева лінія) наборів даних протя-

```
Найкраща конфігурація для оптимізації каналу передачі даних:
OBSS/PD      -62.00000
throughput    25.00000
interference  -80.00000
RSSI         -55.00000
Predicted SINR 1.31782
Name: 1, dtype: float64
```

Рис. 2. Відображення обраної конфігурації параметрів

гом 100 епох навчання моделі. Зменшення Training Loss свідчить про те, що модель поступово покращує свої прогнози на тренувальних даних. Стабілізація Validation Loss після певної кількості епох вказує на те, що модель досягає оптимальної узгодженості з невідомими даними. Відсутність значного розриву між лініями свідчить про те, що модель не схильна до перенавчання.

- Графік середньої абсолютної помилки (MAE).

Графік показує середню абсолютну помилку (MAE) для тренувального (синя лінія) та валідаційного (помаранчева лінія) наборів даних під час навчання моделі. Зменшення MAE з часом вказує на те, що модель поступово покращує точність своїх прогнозів. Мала різниця між тренувальним і валідаційним MAE свідчить про гарну узгодженість моделі з невідомими даними, без ознак перенавчання.

- Графік реального і прогнозованого значення SINR з лінією ідеального прогнозування.

Графік (рис. 5) демонструє співвідношення між реальними (по осі X) і прогнозованими (по осі Y) значеннями SINR. Червона лінія ($y=x$) позначає ідеальні передбачення. Близькість точок до цієї лінії свідчить про високу точність моделі. Розсіювання точок показує відхилення від ідеального прогнозу. Більшість точок розташовані близько до червоної лінії, особливо в середньому діапазоні значень (20–40 SINR). Це свідчить, що модель добре прогнозує значення SINR у цьому діапазоні. У нижніх значеннях SINR (менше 20) та у верхніх значеннях (понад 45) є трохи більша варіативність, що свідчить про складність цих діапазонів для моделі.

- Гістограму абсолютних похибок прогнозування.

Графік (рис. 6) демонструє гістограму абсолютних похибок (absolute errors), які є різницею між реальними значеннями SINR і передбаченими значеннями, у модулі:

$$\text{Absolute Error} = |\text{Real SINR} - \text{Predicted SINR}|$$

Велика частота похибок лежить у межах 0–5, що свідчить про те, що модель здебільшого перед-



Рис. 3. Графік втрат під час навчання




Рис. 4. Графік MAE

бачає SINR із малою помилкою, це вказує на високу якість роботи моделі для більшості зразків.

- Графік реальних і прогнозованих значень SINR.

Графік (рис. 7) порівнює реальні значення SINR (синя лінія) із прогнозованими моделлю (помаранчева лінія) для перших 100 зразків. Близькість обох ліній свідчить про точність прогнозування.

Невеликі розбіжності демонструють похибки моделі, але загальна тенденція зберігається.

Користувач може проаналізувати результати оптимізації та прийняти рішення щодо застосування рекомендованих налаштувань.

Функціональна організація системи

Розроблена система функціонує у двох основних режимах:




Рис. 5. Реальні та прогнозовані значення SINR з лінією ідеального прогнозу




Рис. 6. Частота абсолютних похибок

1. Прогнозування параметрів: Користувач подає вхідні дані, і система прогнозує SINR для заданої конфігурації.

2. Оптимізація параметрів: Система генерує набір конфігурацій, прогнозує для кожної SINR і обирає оптимальну.

Основні компоненти системи:

1. Модуль збору даних. Відповідає за введення та попередню обробку параметрів користувачем. Забезпечує перевірку коректності даних.

2. Нейронна мережа для прогнозування SINR. Складається з трьох шарів що мають 128, 64 та 32 нейрони відповідно. Використовується функція втрат MSE та оптимізатор Adam. Навчена на симуляційних даних із набору formatted_training_data.csv, що являють собою метрики результатів симуляції різних сценаріїв мереж стандарту 802.11ax (WiFi 6) у симуляторі Komondor.

3. Модуль оптимізації реалізує механізм перебору та оцінки можливих конфігурацій та вико-




Рис. 7. Реальне і прогнозоване значення SINR

ристовує прогнозовані значення SINR для вибору найкращої конфігурації.

4. Інтерфейс відображення результатів містить: графіки прогнозування, таблиці з вибраними параметрами, інформацію щодо поточного стану мережі.

Принцип роботи алгоритму:

1. Користувач вводить вхідні параметри мережі (OBSS/PD, throughput, RSSI, interference).

2. Модель прогнозує SINR для заданої конфігурації.

3. Генерується набір конфігурацій, і для кожної прогнозується SINR.

4. Вибирається конфігурація з максимальним SINR.

5. Результати відображаються користувачу у вигляді рекомендацій та графіків.

Переваги створеної системи

- Система автоматично підлаштовується до змін середовища.

- Може працювати з різними конфігураціями параметрів мережі.

- Забезпечує покращення SINR, що безпосередньо впливає на якість зв'язку та каналу передачі.

Розроблена система є інструментом для оптимізації параметрів Wi-Fi мереж і має потенціал для впровадження у сучасні мережеві інфраструктури.

Висновки. Проведено аналіз наявних підходів до оптимізації параметрів бездротових мереж стандарту IEEE 802.11, у ході якого встановлено, що більшість існуючих рішень не враховують динамічних змін середовища, що обмежує їх ефективність.

Наведені приклади досліджень продемонстрували, що хоча машинне навчання має значний потенціал для оптимізації мереж, поточні моделі часто потребують значних обчислювальних ресурсів і не завжди придатні для реального використання.

На основі порівняльного аналізу визначено, що адаптивні підходи до управління параметрами, такі як використання нейронних мереж для прогнозування SINR, мають найвищий потенціал для покращення продуктивності Wi-Fi мереж. Розроблена система відповідає цим вимогам та демонструє високу точність і адаптивність.

Напрямок подальших досліджень є впровадження запропонованого підходу у реальні мережі Wi-Fi, враховуючи мобільність користувачів, енергоефективність системи та багаторівневу оптимізацію параметрів для забезпечення максимальної продуктивності і стабільності мереж нового покоління.

Список літератури:

1. Wi-Fi 6. [Електронний ресурс]. Режим доступу: https://en.wikipedia.org/wiki/Wi-Fi_6
2. Wi-Fi 7. [Електронний ресурс]. Режим доступу: https://en.wikipedia.org/wiki/Wi-Fi_7
3. F. Wilhelmi, B. Bellalta, C. Cano, and A. Jonsson, "Implications of decentralized Q-learning resource allocation in wireless networks," in Proc. IEEE 28th Annu. Int. Symp. Pers. Indoor Mobile Radio Commun. (PIMRC), 2017, pp. 1–5.

4. A. Kumar, G. Verma, C. Rao, A. Swami, and S. Segarra, "Adaptive contention window design using deep Q-learning," in Proc. IEEE Int. Conf. Acoust. Speech Signal Process. (ICASSP), 2021, pp. 4950–4954.
5. S. Khastoo, T. Brecht, and A. Abedi, "NeuRA: Using neural networks to improve WiFi rate adaptation," in Proc. 23rd Int. ACM Conf. Model. Anal. Simul. Wireless Mobile Syst., New York, NY, USA, 2020, pp. 161–170.
6. R. Karmakar, S. De, A. Ghosh, T. Adhikari, and P. Jain, "S2-GI: Intelligent selection of guard interval in high throughput WLANs," in Proc. 11th Int. Conf. Comput. Commun. Netw. Technol. (ICCCNT), 2020, pp. 1–7.
7. D. Skordoulis, Q. Ni, H.-H. Chen, A. P. Stephens, C. Liu, and A. Jamalipour, "IEEE 802.11n MAC frame aggregation mechanisms for next-generation high-throughput WLANs," IEEE Wireless Commun., vol. 15, no. 1, pp. 40–47, Feb. 2008.

Herashchenko A.Yu., Lebedev D.Yu. TECHNOLOGY FOR PREDICTING THE PARAMETERS OF 802.11 WIRELESS NETWORKS FOR ADAPTIVE OPTIMIZATION

The article is devoted to the analysis of modern methods for optimizing the parameters of IEEE 802.11 wireless networks using machine learning approaches. The influence of key network parameters, such as OBSS/PD, throughput, RSSI, and interference, on the quality of data transmission is revealed. The article reviews existing approaches to signal quality prediction based on the signal/interference/noise ratio (SINR) using artificial neural network (ANN) algorithms and adaptive optimization methods.

It has been found that static or empirical methods of network tuning are not effective enough in a dynamic environment. It is proved that the use of machine learning to predict network parameters allows to take into account the variability of the data transmission environment and improves Wi-Fi performance. The article identifies the main disadvantages of traditional approaches, including dependence on static configurations and low adaptability to environmental changes.

A new optimization system is proposed that uses a neural network to accurately predict SINR and dynamically adapt Wi-Fi parameters. The features of automatic optimization are revealed, which increases network performance, ensures data transmission stability, and improves the quality of service in real conditions. The advantages of the proposed approach are determined, in particular, reducing the impact of interference and increasing network efficiency even in complex scenarios.

The article identifies areas for further improvement, including the introduction of multi-level parameter optimization, integration of energy-efficient solutions, and the use of the latest machine learning methods.

It is concluded that adaptive optimization of Wi-Fi networks using artificial intelligence is a promising direction for improving the performance of IEEE 802.11 wireless networks.

Key words: Wi-Fi, SINR, neural network, parameter optimization, machine learning, 802.11.