

ІНТЕГРАЦІЯ НЕЙРОННИХ МЕРЕЖ У МІКРОКОНТРОЛЕРИ ДЛЯ АДАПТИВНОГО КЕРУВАННЯ ЧАСТОТНИМ РЕСУРСОМ В ІОТ- ЕКОСИСТЕМАХ З ВИКОРИСТАННЯМ ПСЕВДОВИПАДКОВОГО НАЛАШТУВАННЯ ЧАСТОТИ

Афанасьєв Ю.В.

Харківський національний університет радіоелектроніки,
кафедра інфокомунікаційної інженерії ім. В.В. Поповського,
Україна

E-mail: yurii.afanasiev@nure.ua

Abstract

The integration of neural networks into microcontroller platforms enables a progressive solution for adaptive frequency resource management within Internet of Things ecosystems. The approach centers on achieving dynamic, interference-resistant frequency allocation to enhance data transmission reliability, especially within dense Internet of Things environments. Traditional frequency hopping spread spectrum techniques, often based on static algorithms, fall short in adaptability, limiting their effectiveness in response to environmental changes and the exponential growth in device connectivity. To address these constraints, an adaptive neural network model is proposed to autonomously generate frequency tables based on real-time environmental assessments. Experimental findings confirm that this approach reduces interference significantly and optimizes data throughput, underscoring its potential to improve the efficiency and stability of IoT networks.

Сучасні екосистеми Інтернету речей (ІоТ-екосистеми) є складними високонавантаженими структурами, що характеризуються експоненційним зростанням кількості підключених пристроїв [1]. Це спричиняє істотне навантаження на частотний ресурс, особливо в бездротових мережах, де концентрація великої кількості пристроїв на обмеженій території призводить до значних втрат даних під час передачі. Одним із методів, що спрямований на подолання цієї проблеми, є псевдовипадкове налаштування частоти (Frequency Hopping Spread Spectrum, FHSS), яке забезпечує розподіл передаваних даних між різними частотними каналами, знижуючи ризик завад. Проте, через свою статичну природу, FHSS-алгоритми мають обмежені можливості адаптації, що перешкоджає ефективному реагуванню на зміни в умовах мережного середовища [2].

Задача полягає у створенні адаптивної системи керування частотами для ІоТ-мереж, яка автоматично підлаштовується до змін у мережевому середовищі, ефективно розподіляючи частоти між пристроями для мінімізації завад. Запропонована система використовує нейронну мережу для генерації частотних таблиць на основі аналізу поточних умов. Водночас, робота не передбачає прямого збору даних про стан середовища, що дозволяє спростити алгоритм та знизити вимоги до обладнання.

Сучасні методи керування частотним ресурсом у ІоТ-системах здебільшого базуються на фіксованих частотних планах та статичних алгоритмах FHSS. Незважаючи на простоту реалізації, такі підходи не забезпечують належної адаптивності до зростаючої кількості пристроїв у мережі або змін у середовищі, що робить систему вразливою до завад і значно знижує її ефективність в умовах динамічних змін.

Запропоновано використання нейронної мережі для генерації частотних таблиць, навчання якої здійснюється на різноманітних алгоритмах розподілу частот, що забезпечує універсальність та адаптивність системи під різні умови мережевого навантаження [3-6].

Для тренування нейронної мережі було застосовано шість основних алгоритмів:

1. Широкий діапазон частот ('g1') — рівномірний розподіл частот у заданому діапазоні для мінімізації перешкод.
2. Фіксований крок ('k2') — частоти генеруються з постійним інтервалом, що забезпечує передбачуваність переходів.
3. Нормальний розподіл ('l3') — частоти слідуєть нормального розподілу, що моделює природні або антропогенні шуми.
4. Експоненційний розподіл ('u4') — генерує частоти з інтенсивними, але рідкими змінами, що ефективно для швидких змін у середовищі.
5. Випадкові зміщення ('h5') — додає випадкові зміни до базових частот, підвищуючи стійкість до передбачуваних атак.
6. Змішаний підхід ('u6') — поєднує рівномірний і нормальний розподіли, створюючи складні патерни частот.

Вхідними параметрами для нейронної мережі є початкова і кінцева частоти, а також ключ, який під час тренування визначає вибір алгоритму. Це дозволяє моделі генерувати частотні таблиці з урахуванням поточного навантаження в мережі. Якщо значна кількість пристроїв працює за одним алгоритмом, система може автоматично перейти на інший, забезпечуючи більш рівномірний розподіл частотного ресурсу та зменшення ризику перешкод.

Після етапу тренування було проведено тестування, яке оцінювало здатність моделі точно передбачати частотні таблиці для кожного з алгоритмів. Основними вхідними параметрами для адаптивного керування частотними ресурсами використано початкову та кінцеву частоти, що визначають діапазон, у якому модель генерує частотну сітку.

На рисунку 1 наведено результати порівняння між фактичними (True Frequencies) та передбаченими (Predicted Frequencies) значеннями частот для кожного з шести алгоритмів. Із графіків видно, що модель забезпечує високу точність передбачень для алгоритмів із регулярними частотними патернами, зокрема 'k2' (Фіксований крок) та 'l3' (Нормальний розподіл). Частотні значення для цих алгоритмів мають мінімальні відхилення від фактичних значень, що вказує на здатність моделі відтворювати передбачувані та регулярні розподіли частот. Це підкреслює високу точність та потенціал нейронної мережі для моделювання статичних і передбачуваних частотних патернів.




Рис. 1. Порівняння фактичних та передбачених частот для різних алгоритмів генерації частотних таблиць

Для алгоритмів із більшою варіативністю, як-от 'g1' (Широкий діапазон частот) та 'u6' (Змішаний підхід), характерні більші розбіжності між фактичними та передбаченими значеннями. Це зумовлено їх

складною та менш передбачуваною природою, яка породжує частотні патерни зі значною мінливістю. Попри такі розбіжності, модель продемонструвала здатність визначати загальні тренди, що свідчить про її перспективи для подальшого вдосконалення у роботі з динамічними й нестабільними частотними розподілами.

Для забезпечення роботи нейромережі на пристроях з обмеженими ресурсами модель було перетворено у формат TensorFlow Lite, який оптимізує використання. Це дозволяє ефективно запускати нейромережу на мікроконтролерах з обмеженими обчислювальними можливостями, що є важливим для IoT-додатків. Після такої оптимізації модель може працювати на платформах: Arduino (Nano 33 BLE Sense, Portenta H7), ESP32 (ESP32, ESP32-S2, ESP32-S3), STM32 (STM32F7, STM32H7, STM32L4) та Raspberry Pi (Raspberry Pi Pico).

Отримані результати підтверджують, що запропонований метод адаптивного керування частотними ресурсами може бути успішно реалізований на пристроях з обмеженими ресурсами, таких як мікроконтролери ESP32. У рамках дослідження було розроблено нейронну мережу, здатну генерувати частотні таблиці з високою точністю та узгодженістю між пристроями за однакових вхідних параметрів, що забезпечує синхронізовану роботу в мережі FHSS і мінімізує конфлікти під час передачі даних.

Для підвищення гнучкості та стійкості системи запропоновано навчати нейронну мережу на основі кількох алгоритмів розподілу частот, що дає можливість переходити між ними залежно від кількості пристроїв або змін у середовищі. Такий підхід забезпечує рівномірніший розподіл частотного ресурсу та підвищену стійкість до завад, що є важливим для динамічних IoT-екосистем із високою щільністю підключених пристроїв.

Підхід, що запропоновано для адаптивного керування частотами в IoT-екосистемах дозволяє здійснювати їх впровадження в різних перспективних проєктах економічного розвитку України [7].

Література

1. Internet of Things (IoT): Opportunities, issues and challenges towards a smart and sustainable future / S. Nižetić et al. Journal of Cleaner Production. 2020. Vol. 274. P. 122877. URL: <https://doi.org/10.1016/j.jclepro.2020.122877> (date of access: 15.10.2024).
2. Compacting Deep Neural Networks for Internet of Things: Methods and Applications / K. Zhang et al. IEEE Internet of Things Journal. 2021. Vol. 8, no. 15. P. 11935–11959. URL: <https://doi.org/10.1109/jiot.2021.3063497> (date of access: 15.10.2024).
3. Ristić V., Todorović B., Stojanović N. Frequency hopping spread spectrum: History, principles and applications. Vojnotehnicki glasnik. 2022. Vol. 70, no. 4. P. 856–876. URL: <https://doi.org/10.5937/vojtehg70-38342> (date of access: 18.10.2024).
4. Scalable training of artificial neural networks with adaptive sparse connectivity inspired by network science / D. C. Mocanu et al. Nature Communications. 2018. Vol. 9, no. 1. URL: <https://doi.org/10.1038/s41467-018-04316-3> (date of access: 18.10.2024).
5. Parameter Estimation of Multi Frequency Hopping Signals Based on Space-Time-Frequency Distribution / J. Wan et al. Symmetry. 2019. Vol. 11, no. 5. P. 648. URL: <https://doi.org/10.3390/sym11050648> (date of access: 18.10.2024).
6. Machine Learning Based Prediction of Frequency Hopping Spread Spectrum Signals / P. Thiele et al. 2023 IEEE 34th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC), Toronto, ON, Canada, 5–8 September 2023. URL: <https://doi.org/10.1109/pimrc56721.2023.10293939> (date of access: 18.10.2024).
7. Стратегії розвитку “Індустрія 4.0”. [Електронний ресурс] – Режим доступу до ресурсу: <https://mautic.appau.org.ua/asset/42:strategia-rozvitku-4-0-v3pdf> (дата звернення: 18.10.2024).