

Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерної інженерії та управління _____

Кафедра _____ електронних обчислювальних машин _____

Рівень вищої освіти _____ другий (магістерський) _____

Спеціальність _____ 123 «Комп'ютерна інженерія» _____
(код і повна назва)

Тип програми _____ освітньо-наукова _____
(освітньо-професійна або освітньо-наукова)

Освітня програма _____ Системне програмування _____
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

“ _____ ” _____ 20__ р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві _____ Гармаш Владіслав Сергійович _____
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Метод енергозбереження в безпроводних сенсорних мережах _____

затверджена наказом по університету від “ 21 ” квітня 2025 р. № 296 Ст

2. Термін подання здобувачем роботи до екзаменаційної комісії _____ 16 червня 2025 р.

3. Вхідні дані до роботи _____

WSN

вузол живлення

машинне навчання

метод енергозбереження

Google Colab

Python

4. Перелік питань, що потрібно опрацювати у роботі _____

Аналіз проблеми енергозбереження в безпроводних сенсорних мережах

Використання карт кохонена для оптимізації енергоспоживання WSN

Реалізація програмного прототипу методу та аналіз результатів

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій 16 слайдів

6. Консультанти розділів роботи (заповнюється за наявності консультантів згідно з наказом, зазначеним у п.1)


Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Строк / терміни виконання етапів роботи	Примітка
1	Отримання завдання та аналіз літератури	21.04.2025–30.04.2025	
2	Огляд існуючих рішень та алгоритмів	01.05.2025–12.05.2025	
3	Розробка методу	13.05.2025–22.05.2025	
4	Вибір програмних засобів	23.05.2025–30.05.2025	
5	Програмна реалізація	31.05.2025–02.06.2025	
6	Аналіз отриманих результатів	03.06.2025–05.06.2025	
7	Оформлення записки	06.06.2025–12.06.2025	

Дата видачі завдання “ 21 ” квітня 2025 р.

Здобувач


(підпис)

Керівник роботи

(підпис)

проф. Олег МІХАЛЬ

(посада, власне ім'я, прізвище)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 62 с., 13 рис., 3 дод., 7 джерел.

БЕЗПРОВІДНА СЕНСОРНА МЕРЕЖА, ЕНЕРГОЗБЕРЕЖЕННЯ, МАШИННЕ НАВЧАННЯ, КАРТА КОХОНЕНА, SOM, КЛАСТЕРИЗАЦІЯ, МАРШРУТИЗАЦІЯ, АДАПТИВНЕ КЕРУВАННЯ, MINISOM, ІНТЕЛЕКТУАЛЬНА СИСТЕМА, ВІЗУАЛІЗАЦІЯ, ЕНЕРГОЗВАЖЕНЕ ОНОВЛЕННЯ, ТОПОЛОГІЯ МЕРЕЖІ, АВТОНОМНА СИСТЕМА.

Метою кваліфікаційної роботи розробка та дослідження методу енергозбереження у безпроводних сенсорних мережах на основі використання алгоритмів машинного навчання, зокрема штучних нейронних мереж типу карт Кохонена та їх модифікацій, для забезпечення максимально ефективного використання енергетичних ресурсів вузлів, оптимізації процесів передачі та обробки даних, а також збільшення періоду автономної роботи та надійності функціонування сенсорних мереж у змінних умовах експлуатації.

У ході кваліфікаційної роботи у рамках реалізації методу було використано бібліотеку MiniSom у середовищі Google Colab, реалізовано енергозважену функцію оновлення ваг, інкрементальне навчання та адаптивне регулювання радіуса сусідства. На основі карти Кохонена виконано кластеризацію вузлів та визначення кластерних центрів, побудовано маршрути передачі з урахуванням мінімізації енергетичних втрат і проілюстровано результати візуально. Проведено порівняльний аналіз ефективності розробленого підходу з класичними методами керування, що підтвердив переваги використання SOM у задачах розподіленого енергозбереження.

ABSTRACT

Master's thesis: 62 pages, 13 figures, 3 appendices, 7 sources.

WIRELESS SENSOR NETWORK, ENERGY EFFICIENCY, MACHINE LEARNING, KOHONEN MAP, SOM, CLUSTERING, ROUTING, ADAPTIVE CONTROL, MINISOM, INTELLIGENT SYSTEM, VISUALIZATION, ENERGY-AWARE UPDATE, NETWORK TOPOLOGY, AUTONOMOUS SYSTEM.

The major goal of this thesis is the development and investigation of an energy-saving method for wireless sensor networks based on machine learning algorithms, specifically artificial neural networks of the Kohonen map type and their modifications. The goal is to ensure the most efficient utilization of node energy resources, to optimize data transmission and processing, and to extend the autonomous operation period and reliability of sensor networks under changing operational conditions.

In order to as part of the implementation of the proposed method, the MiniSom library was used within the Google Colab environment. The approach includes the implementation of an energy-aware weight update function, incremental learning, and adaptive regulation of the neighborhood radius. Based on the Kohonen map, node clustering and cluster head selection were performed, and data transmission routes were constructed with consideration of energy loss minimization. The results were visually illustrated.

A comparative analysis of the efficiency of the developed approach against classical control methods was conducted, confirming the advantages of using SOM in distributed energy-saving tasks.

ЗМІСТ

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ	8
ВСТУП	9
1 АНАЛІЗ ПРОБЛЕМИ ЕНЕРГОЗБЕРЕЖЕННЯ В БЕЗПРОВІДНИХ СЕНСОРНИХ МЕРЕЖАХ	12
1.1 Аналіз літератури	15
1.2 Особливості функціонування та сфери застосування WSN	17
1.3 Ключові проблеми енергоспоживання у WSN	19
1.4 Сучасні підходи до зменшення енергоспоживання у WSN.....	21
1.5 Перспективи використання штучних нейронних мереж у задачах енергозбереження.....	23
2 ВИКОРИСТАННЯ КАРТ КОХОНЕНА ДЛЯ ОПТИМІЗАЦІЇ ЕНЕРГОСПОЖИВАННЯ WSN.....	26
2.1 Аналіз та порівняння ефективності алгоритмів кластеризації, класифікації та прогнозування	26
2.2 Застосування самоорганізаційних карт Кохонена для оптимізації енергоспоживання у WSN.....	29
2.3 Модифікації процесу навчання карт Кохонена для забезпечення енергоефективності в WSN	31
2.4 Розробка методу	34
2.4 Етапи розробленого методу	36
2.5 Висновки до методу	38
3 РЕАЛІЗАЦІЯ ПРОГРАМНОГО ПРОТОТИПУ МЕТОДУ ТА АНАЛІЗ РЕЗУЛЬТАТІВ.....	40
3.1 Обґрунтування вибору середовища та бібліотек	40
3.2 Формування початкових даних	40
3.3 Первинне навчання карти Кохонена	41
3.4 Кластеризація вузлів та візуалізація результатів.....	41

3.5 Формування маршрутів і енергозберігаючих режимів	41
3.6 Перенавчання карти в онлайн-режимі	42
3.7 Підсумкова візуалізація та оцінка ефективності	42
3.8 Аналіз результатів	43
ВИСНОВКИ	46
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ	48
ДОДАТОК А Графічний матеріал кваліфікаційної роботи	49
ДОДАТОК Б Програмний код	58
Б.1 Встановлення бібліотек та завантаження даних	58
Б.2 Передобробка та нормалізація. Навчання модифікованої карти Кохонена	58
Б.3 Кластеризація та вибір кластерних голів. Побудова маршрутів та імітація трафіку	59
Б.4 Візуалізація результатів	59
ДОДАТОК В Додаткові дослідження	60

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ

AI – штучний інтелект

ANN – штучна нейронна мережа

BS – базова станція

CNN – згорткова нейронна мережа

DL – глибоке навчання

DL-GMA – алгоритм групування на основі глибокого навчання

GNN – графова нейронна мережа

IoT – інтернет речей

LEACH – адаптивна ієрархія кластеризації з низьким енергоспоживанням

MAC – рівень керування доступом до середовища

ML – машинне навчання

QoS – якість обслуговування

RSSI – індикатор рівня отриманого сигналу

SNR – співвідношення сигнал/шум

SOM – самоорганізувальна карта

UAV – безпілотний літальний апарат

WSN – безпроводна сенсорна мережа

ZLE – зона з низьким енергоспоживанням

ВСТУП

У сучасних умовах безпроводні сенсорні мережі відіграють фундаментальну роль у забезпеченні функціонування критично важливих систем різного призначення. Їхнє активне впровадження спостерігається у багатьох секторах людської діяльності, де необхідне постійне відстеження параметрів середовища, оперативне прийняття рішень на основі актуальних даних та забезпечення адаптивного керування у реальному часі. Здатність таких мереж до масштабованого збору, обробки та передавання інформації, отриманої з великої кількості просторово рознесених сенсорних вузлів, стала передумовою для їх інтеграції в інтелектуальні технології майбутнього. Проте інтенсивне зростання обсягів оброблюваних даних, збільшення щільності розміщення сенсорних елементів та розширення ареалу їх використання висуває нові вимоги до енергетичної автономності компонентів системи.

Найбільш значущим викликом, з яким стикаються розробники і дослідники у цій галузі, є забезпечення тривалого функціонування сенсорних вузлів у режимі повної автономності, без потреби в частій заміні джерел живлення або підзарядці акумуляторів. У практичних сценаріях, особливо в умовах обмеженого доступу до фізичної інфраструктури або у віддалених місцевостях, така заміна стає не лише технічно складною, а й економічно недоцільною. У результаті цього, проблема енергозбереження набуває критичного значення, оскільки від неї прямо залежить життєвий цикл мережі та її здатність до довготривалої ефективної експлуатації.

Ситуація ускладнюється тим, що енерговитрати сенсорного вузла зумовлені не тільки процесом передавання даних, але й супутніми операціями – зокрема, прийманням сигналів, локальною обробкою інформації та підтриманням базової працездатності навіть у стані очікування. Враховуючи жорсткі обмеження щодо доступних енергоресурсів, актуальним

стає пошук інтегрованих підходів, які дозволяють оптимізувати енергоспоживання без втрати продуктивності або надійності роботи.

У цьому контексті метою даної роботи є комплексне дослідження наявних технологічних рішень, спрямованих на зниження енергоспоживання у безпроводних сенсорних мережах. Особливу увагу зосереджено на аналізі протоколів енергоефективної маршрутизації, механізмів управління режимами активності вузлів, методів попередньої обробки даних з метою зменшення навантаження на канал зв'язку, а також на підходах до адаптивного регулювання потужності передавання сигналу. Окремо розглядаються можливості використання альтернативних джерел енергії для забезпечення тривалого автономного функціонування сенсорних пристроїв. Проведений аналіз дозволяє сформулювати обґрунтовані висновки та рекомендації щодо інтегрованого використання зазначених методів, що в перспективі забезпечить підвищення енергоефективності та стійкості безпроводних сенсорних мереж у реальних умовах експлуатації.

Метою кваліфікаційної роботи є розробка та дослідження методу енергозбереження у безпроводних сенсорних мережах на основі використання алгоритмів машинного навчання, зокрема штучних нейронних мереж типу карт Кохонена та їх модифікацій, для забезпечення максимально ефективного використання енергетичних ресурсів вузлів, оптимізації процесів передачі та обробки даних, а також збільшення періоду автономної роботи та надійності функціонування сенсорних мереж у змінних умовах експлуатації.

Об'єктом дослідження є процеси енергоспоживання та функціонування безпроводних сенсорних мереж.

Завдання:

- провести аналіз сучасного стану досліджень у сфері енергозбереження в безпроводних сенсорних мережах та виявити основні фактори, що впливають на енергетичну ефективність вузлів;
- розглянути можливості використання методів машинного навчання

для вирішення задач оптимізації енергоспоживання в WSN, з акцентом на нейронні мережі самоорганізації типу карт Кохонена;

- дослідити модифікації процесу навчання карт Кохонена, орієнтовані на підвищення енергоефективності при обмежених ресурсах сенсорних вузлів;

- розробити метод енергозбереження, який базується на динамічному кластеруванні вузлів із використанням модифікованої карти Кохонена та адаптивному управлінні режимами їх роботи;

- реалізувати запропонований метод у вигляді програмної моделі в середовищі Google Colab із використанням Python, бібліотеки MiniSom та засобів візуалізації;

- провести експериментальне дослідження ефективності розробленого методу на штучно згенерованих даних з оцінкою показників енергоспоживання, розподілу навантаження та тривалості автономної роботи мережі.

1 АНАЛІЗ ПРОБЛЕМИ ЕНЕРГОЗБЕРЕЖЕННЯ В БЕЗПРОВІДНИХ СЕНСОРНИХ МЕРЕЖАХ

Функціональна ефективність сенсорних вузлів у безпроводних сенсорних мережах визначається складною взаємодією апаратних і програмних характеристик, а також чинників навколишнього середовища. Кожен з цих компонентів суттєво впливає на параметри енергоспоживання, стабільності зв'язку, обчислювальної ефективності та тривалості автономної експлуатації. До числа критичних аспектів належить вибір сенсорів із відповідною чутливістю та роздільною здатністю, що безпосередньо позначається на інтенсивності споживання енергії; архітектура та продуктивність мікроконтролера, який забезпечує локальну обробку даних, але водночас формує додаткове навантаження на джерела живлення; а також ємність акумуляторів або особливості систем енергозбирання, що визначають тривалість функціонування пристрою без обслуговування.

Раціональне управління енергетичними режимами, включаючи переходи між станами активності, очікування чи сну, потребує інтеграції адаптивних стратегій контролю, які мають враховувати як внутрішній стан вузлів, так і зовнішні впливи. Додатково, протоколи зв'язку, топологія мережі, алгоритми маршрутизації, а також інтенсивність і періодичність обміну інформацією істотно впливають на загальне енергетичне навантаження в системі. Оточуючі фізичні умови, такі як температура, вологість, рельєф місцевості або наявність радіоперешкод, також є значущими чинниками, що модулюють стабільність зв'язку та потребують динамічного коригування параметрів роботи вузлів (рисунок 1.1). Важливу роль відіграє також якість програмного забезпечення, зокрема ефективність планування задач і здатність до локального аналізу даних, що дозволяє зменшити частоту передачі інформації до центральних вузлів або серверів.

Традиційні підходи до управління ресурсами WSN, базовані на фіксованих правилах або статистичних моделях, мають обмежені можливості адаптації до змінних умов експлуатації, таких як деградація елементів живлення, неоднорідне навантаження чи динаміка середовища (рисунок 1.2). У зв'язку з цим дедалі актуальнішим стає впровадження методів машинного навчання, які забезпечують здатність системи до навчання на основі накопиченого досвіду, прогнозування майбутніх станів і прийняття адаптивних рішень.



Рисунок 1.1 – Проблеми енергоживлення в безпроводних сенсорних мережах

Одним із ключових напрямів оптимізації енергоспоживання є динамічне кластерування вузлів мережі, що дозволяє формувати кластери з

урахуванням рівня заряду батарей, просторового розташування та навантаження. Алгоритми машинного навчання, зокрема методи k-середніх, ієрархічне групування або самоорганізаційні нейронні мережі, забезпечують автоматизоване визначення оптимальної структури кластерів та їх оновлення в реальному часі. Це дозволяє рівномірно розподіляти навантаження між вузлами, зменшуючи енергетичні витрати на маршрутизацію.

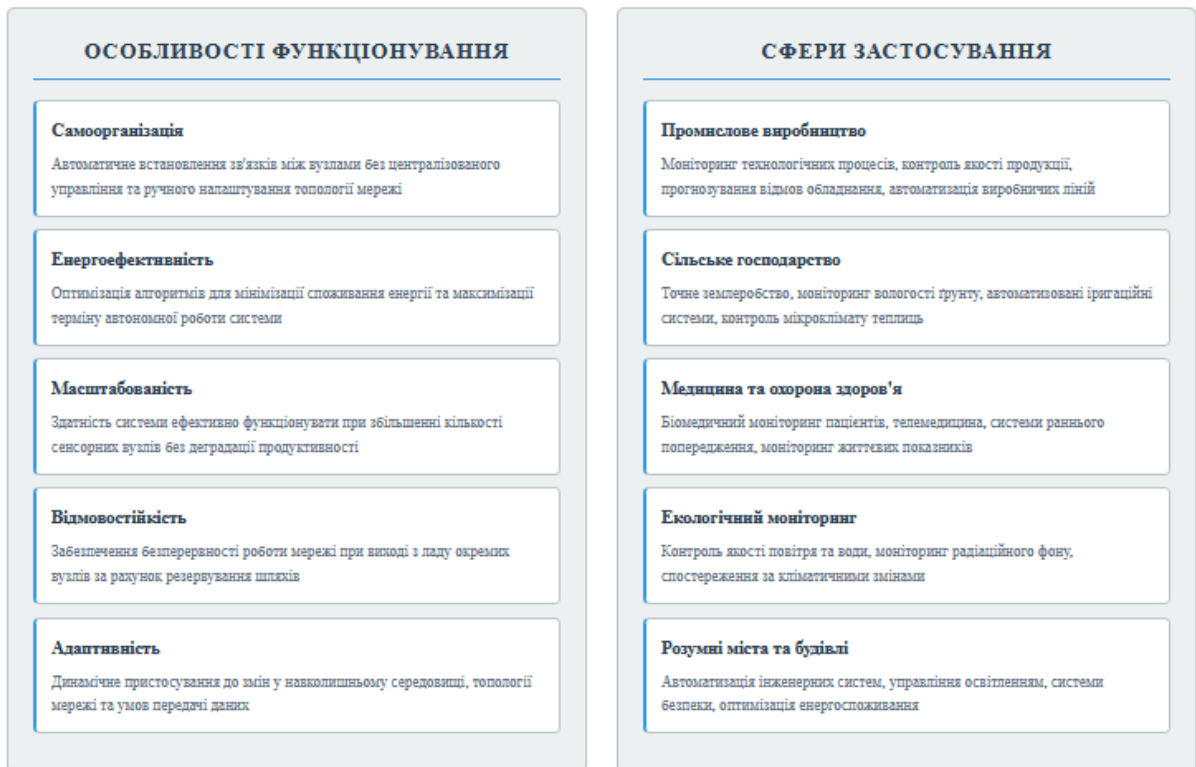


Рисунок 1.2 – Особливості функціонування та сфери застосування безпроводних сенсорних мереж

Іншим перспективним підходом є прогнозування активності вузлів на основі аналізу історичних даних, циклічних закономірностей або змін у зовнішньому середовищі. Такий підхід дає змогу ефективно керувати переходами вузлів між енергетичними режимами, зменшуючи непотрібне енергоспоживання в періоди низької активності. Алгоритми класифікації та регресії забезпечують оперативне оцінювання стану мережі та прийняття рішень щодо переадресації трафіку або зміни потужності передавача.

Значну увагу також привертають підходи, що базуються на навчанні з

підкріпленням, коли вузли здатні навчатися через взаємодію з мережею і середовищем шляхом проб і помилок, отримуючи «винагороду» за енергоефективну поведінку. Це сприяє формуванню гнучких стратегій керування, які дозволяють адаптувати поведінку мережі до змінних умов у режимі реального часу.

У найбільш передових дослідженнях застосовуються моделі глибинного навчання, включаючи згорткові та рекурентні нейронні мережі, які дозволяють виявляти складні часові та просторові закономірності у великих масивах даних. Це відкриває можливості для реалізації проактивного управління енерговитратами, прогнозування критичних навантажень і підтримання стабільності функціонування систем у складних та динамічних умовах.

1.1 Аналіз літератури

У роботі [1] обґрунтовується ефективність використання модифікованого алгоритму самоорганізувальних карт Кохонена для оптимізації функціонування безпроводних сенсорних мереж. Запропоновано підхід до кластеризації вузлів за такими параметрами, як кількість стрибків маршруту, залишковий рівень енергії, чутливість сенсорів і затримка передачі, що дозволяє обрати найбільш доцільних кандидатів для виконання ключових функцій мережі. Основна ідея полягає у групуванні даних, отриманих з різних сенсорів, із подальшою передачею лише з найбільш доцільних вузлів, що суттєво зменшує сумарне енергоспоживання.

У дослідженні [2] розглянуто DL-GMA – метод глибокого групування для підвищення енергоефективності в сенсорних мережах. Використання глибоких нейронних мереж у поєднанні з розвиненими механізмами кластеризації дозволило значно зменшити навантаження на комунікаційну підсистему, покращити масштабованість і стабільність функціонування мережі. Проте автори наголошують на деяких обмеженнях застосування

цього підходу, зокрема у контексті гетерогенності топологій, мобільності вузлів, обмежених ресурсів комунікації та недостатньої репрезентативності тестового середовища.

У праці [3] запропоновано концептуальну інтегровану модель, яка базується на методах інтелектуального аналізу даних та машинного навчання. В основі лежить принцип поєднання задач вибору сенсорів і виявлення подій у межах єдиного фреймворку, що навчається на основі історичних даних. Автор демонструє, що такий підхід дозволяє одночасно вирішувати низку операційних завдань, зокрема забезпечення енергоефективності, точності спрацювань і підтримки якості обслуговування в умовах відмов окремих вузлів. Попри це, у роботі зазначено низку відкритих проблем, пов'язаних із функціональними обмеженнями та ймовірністю перенавчання, що вимагає подальших досліджень.

Загальний аналіз наведених джерел підтверджує доцільність і високу ефективність використання самоорганізувальних карт Кохонена як засобу інтелектуального управління енергоспоживанням у безпроводних сенсорних мережах. У межах цієї парадигми реалізується концепція оптимального функціонального розподілу ролей між вузлами, що дозволяє знижувати навантаження на енергетичну інфраструктуру. Саме завдяки здатності до автоматичного навчання без попередньої розмітки даних, такі нейромережі здатні формувати топологічно впорядковані кластери вузлів на основі низки параметрів: стану батареї, рівня трафіку, показників радіозв'язку тощо. Це дає змогу виділяти енергетично доцільні центри кластерів, які надалі виконуватимуть роль ретрансляторів або маршрутизаторів.

Ключовою перевагою використання карт Кохонена у сфері енергозбереження є їх здатність до адаптації без участі оператора. Такий підхід дозволяє самостійно оновлювати структуру кластерів у разі зміни топології мережі, виходу з ладу окремих вузлів або змін у навколишньому середовищі. Це забезпечує високу гнучкість і надійність у динамічних і важкодоступних середовищах, де переважно застосовуються WSN.

Однак, у сучасних умовах класична архітектура карт Кохонена або стандартні процедури навчання можуть бути недостатніми для ефективної роботи в складних, динамічних і масштабованих мережах [4]. У зв'язку з цим з'являються модифікації, спрямовані на підвищення точності адаптації в реальному часі, масштабованості до великої кількості вузлів та стабільності навчання. Такі удосконалення дозволяють використовувати картографічні моделі навіть у середовищах з високим рівнем навантаження та частими топологічними змінами.

Серед перспективних архітектур вирізняється ієрархічна організація самоорганізаційних карт, де декілька рівнів нейронних мереж відповідають за кластеризацію на різній глибині представлення даних. Така структура дозволяє забезпечити багаторівневу агрегацію інформації з урахуванням просторового розташування вузлів і локальних умов функціонування. Як наслідок, знижується кількість міжкластерних передач, зменшується енергоспоживання, а управління мережею здійснюється більш ефективно на локальному рівні без втрати загальної узгодженості.

1.2 Особливості функціонування та сфери застосування WSN

Функціонування безпроводних сенсорних мереж WSN базується на взаємодії великої кількості мініатюрних сенсорних вузлів, які автономно здійснюють моніторинг фізичних, хімічних або біологічних параметрів навколишнього середовища та забезпечують передачу зібраних даних до центрального вузла або шлюзу для подальшої обробки. Такі системи відзначаються високою гнучкістю, масштабованістю та здатністю працювати в умовах мінімального втручання людини. Архітектура WSN зазвичай передбачає багаторівневу структуру, що включає вузли збору даних, маршрутизуючі вузли та базову станцію, яка слугує точкою інтеграції інформації з усієї мережі.

Основою функціонування WSN є кооперативна передача даних, яка відбувається через багатострибкову маршрутизацію, що дозволяє значно зменшити енергоспоживання порівняно з прямою передачею на великі відстані. Ефективність роботи таких мереж визначається цілою низкою чинників, зокрема продуктивністю обчислювальних модулів сенсорних вузлів, обсягом енергетичних ресурсів, які забезпечують автономну роботу пристроїв, а також здатністю мережі адаптуватися до змін у топології, викликаних виходом з ладу окремих вузлів чи зміною середовища. Стійкість до відмов і здатність до самовідновлення є критично важливими характеристиками, особливо в умовах обмеженого фізичного доступу до пристроїв.

Що стосується галузей застосування, то безпроводні сенсорні мережі відіграють ключову роль у широкому спектрі сучасних технологічних рішень. В екологічному моніторингу вони дозволяють у режимі реального часу відстежувати зміну кліматичних умов, вологість ґрунту, рівень забруднення повітря або води, забезпечуючи таким чином прийняття рішень на основі актуальних даних. У промисловості WSN широко застосовуються для контролю за параметрами технологічного процесу, виявлення несправностей обладнання та прогнозування технічного обслуговування, що значно знижує ризик простоїв і аварій (рисунок 1.3). У медицині ці мережі забезпечують безперервний збір біомедичних даних пацієнтів, сприяючи впровадженню концепції персоніфікованої медицини та дистанційного медичного нагляду.

Інтелектуальні транспортні системи, агропромислові комплекси, системи "розумного дому" та "розумного міста", військова розвідка і безпека – всі ці галузі дедалі активніше інтегрують рішення на основі WSN, оскільки вони дозволяють реалізувати децентралізований підхід до збору та обробки даних у географічно розподілених середовищах. У контексті розвитку Інтернету речей WSN відіграють роль основного комунікаційного шару, що забезпечує підключення фізичних об'єктів до інформаційних систем. У

результаті, функціональні характеристики таких мереж визначаються не лише їх апаратною реалізацією, а й гнучкістю програмної платформи, яка повинна забезпечувати обробку, фільтрацію, агрегацію та збереження даних, дотримуючись при цьому обмежень щодо енергоспоживання, затримки та надійності передачі.

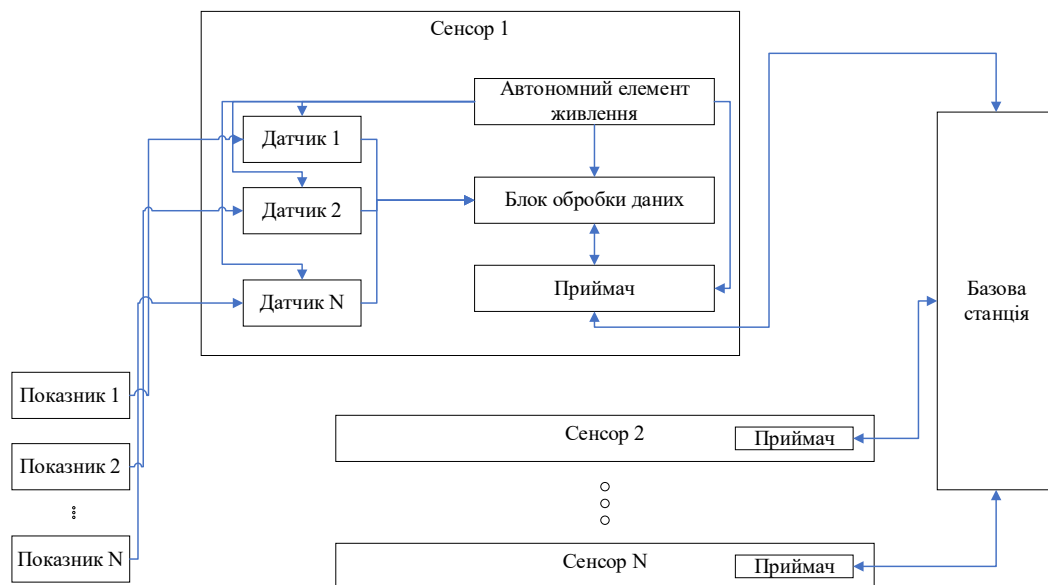


Рисунок 1.3 – Аналіз енергоживлення вузла бездротової сенсорної мережі

Сучасний розвиток безпроводних сенсорних мереж рухається у напрямку підвищення автономності, зменшення енергетичних витрат, удосконалення адаптивності до умов експлуатації та впровадження елементів штучного інтелекту для прийняття рішень без централізованого втручання.

Застосування методів машинного навчання, зокрема для оптимізації маршрутів передачі, виявлення аномалій, прогнозування навантаження чи адаптації режимів роботи вузлів, є важливим чинником майбутнього розвитку WSN як основи цифрових кіберфізичних систем.

1.3 Ключові проблеми енергоспоживання у WSN

Безпроводні сенсорні мережі, будучи автономними розподіленими системами, зазвичай функціонують у середовищах з обмеженим фізичним

доступом, що унеможливорює регулярне технічне обслуговування, зокрема заміну або підзарядку джерел живлення (рисунок 1.4). У зв'язку з цим проблема енергоспоживання стає ключовим технічним викликом, який визначає не лише тривалість автономної роботи сенсорних вузлів, а й загальну ефективність і надійність функціонування всієї мережі.

Основна частина енергетичних ресурсів у сенсорних вузлах витрачається на обробку, зберігання, приймання та передачу інформації. Найбільш енерговитратними операціями є саме передача даних, що особливо критично для вузлів, які виступають у ролі ретрансляторів у багатострибкових маршрутах. У таких умовах спостерігається явище енергетичної нерівномірності, коли вузли, що опинилися в центральних або найбільш навантажених частинах мережі, виснажуються значно швидше, що призводить до розривів у комунікаціях та деградації топології мережі.

Іншим важливим аспектом є недостатня адаптивність до зміни навколишнього середовища. Відсутність механізмів динамічного налаштування режимів роботи вузлів з урахуванням поточного рівня енергозабезпечення, навантаження на канал зв'язку або температурного режиму призводить до нераціонального витрачання енергії. Більше того, традиційні протоколи зв'язку та маршрутизації не завжди передбачають можливості для балансування навантаження між вузлами, що посилює проблему передчасного виснаження окремих елементів системи.

Проблеми енергозбереження також пов'язані з високою частотою генерації даних у застосуваннях, які передбачають безперервний моніторинг. Часте вимірювання та передача великого обсягу інформації без попереднього аналізу або агрегації значно підвищують загальні витрати енергії. Водночас відмова від передавання менш важливої або надлишкової інформації без втрати точності – складне завдання, що вимагає впровадження інтелектуальних алгоритмів попередньої обробки.

Ще однією проблемою є обмеженість обчислювальних ресурсів сенсорних вузлів, що ускладнює застосування традиційних алгоритмів

енергозбереження з високими обчислювальними або пам'яттєвими вимогами. Це особливо актуально при розгляді питань локальної оптимізації маршрутів або адаптивного управління режимами роботи, де кожне рішення повинно прийматися з мінімальними витратами процесорного часу та енергії.

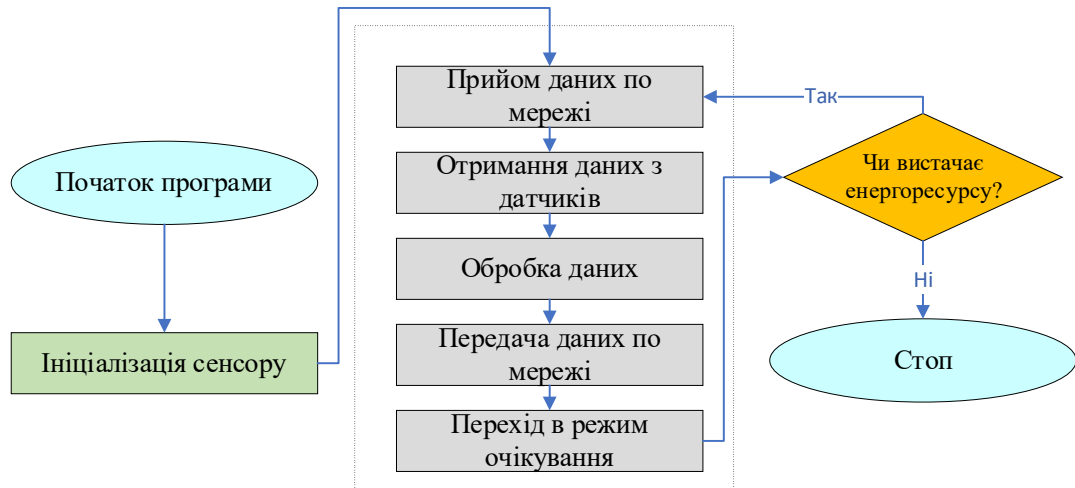


Рисунок 1.4 – Алгоритм роботи сенсора WSN

У зв'язку з цим актуальним напрямом досліджень є інтеграція методів машинного навчання [5] в задачі управління енергоспоживанням, зокрема з метою прогнозування поведінки вузлів, класифікації важливості інформації, адаптації маршрутів передачі та динамічної кластеризації. Саме така інтеграція дозволяє не лише підвищити ефективність використання енергетичних ресурсів, а й забезпечити адаптивність і життєздатність мережі в умовах мінливого навколишнього середовища та обмеженості ресурсів. У результаті, комплексне врахування всіх факторів, що впливають на енергоспоживання, є критично важливим для створення стійких, довговічних та інтелектуально керованих сенсорних систем.

1.4 Сучасні підходи до зменшення енергоспоживання у WSN

Проблематика ефективного енергоспоживання у WSN на сьогодні залишається одним із найбільш пріоритетних напрямів дослідження в галузі

розподілених обчислень та інтернету речей. Основна увага зосереджена на розробці таких підходів, які дозволяють досягти балансу між мінімальними енергетичними витратами вузлів і збереженням якості функціонування мережі, включаючи надійність передачі даних, масштабованість, відмовостійкість і часову узгодженість.

Одним із найпоширеніших напрямів є оптимізація протоколів маршрутизації. У рамках цього підходу реалізуються енергозберігаючі алгоритми, що мінімізують кількість стрибків або обирають маршрути залежно від залишкового заряду батарей вузлів. Зокрема, активно досліджуються протоколи на основі кластеризації, у яких вузли об'єднуються у кластери, а передача даних до базової станції здійснюється через вибрані головні вузли, що дозволяє зменшити кількість передач на великі відстані. Протоколи типу LEACH, HEED, TEEN та їх численні модифікації залишаються актуальними завдяки своїй гнучкості та простоті реалізації.

Іншим важливим підходом є запровадження режимів сну та пробудження вузлів. Сенсорні пристрої, що не залучені до активної передачі даних, можуть тимчасово переходити у стан низького енергоспоживання, що дозволяє суттєво знизити витрати енергії на підтримання зв'язку. Управління цими режимами часто здійснюється за допомогою алгоритмів з адаптивним плануванням активності, які враховують як локальну інтенсивність подій, так і часові шаблони роботи.

Актуальною також є стратегія зменшення обсягу переданої інформації через попередню обробку та агрегацію даних безпосередньо на рівні сенсорного вузла або в межах кластеру. Замість надсилання сирих даних, вузли можуть здійснювати фільтрацію, усереднення, виявлення аномалій або подій, надсилаючи лише значущі повідомлення. Такі підходи дозволяють не лише зменшити енергетичні витрати, але й знизити навантаження на комунікаційні канали.

У сучасних дослідженнях активно впроваджуються методи машинного навчання, які дозволяють побудувати адаптивні схеми керування

енерговитратами на основі аналізу історичних даних та поточного стану мережі. Самоорганізаційні нейронні мережі, алгоритми кластеризації, дерева рішень, ансамблеві моделі і навчання з підкріпленням забезпечують можливість динамічного прийняття рішень щодо маршрутизації, активації вузлів, передбачення навантаження або виявлення неефективних топологічних структур. Перевагою таких підходів є їх здатність до самонавчання та адаптації без необхідності зовнішнього втручання, що особливо важливо в розподілених і віддалених системах.

Крім того, перспективними напрямками вважаються застосування технологій відновлюваної енергії, зокрема збирання енергії із джерел навколишнього середовища: сонячної, вітрової, термоелектричної або вібраційної енергії. Поєднання цих технологій із алгоритмами адаптивного управління дозволяє значно продовжити життєвий цикл мережі та забезпечити її стійкість навіть за несприятливих умов.

1.5 Перспективи використання штучних нейронних мереж у задачах енергозбереження

У контексті WSN, штучні нейронні мережі (ШНМ) виступають потужним інструментом для вирішення задач, пов'язаних з адаптивним керуванням ресурсами, прогнозуванням динаміки мережі та зменшенням енергоспоживання. Завдяки здатності до навчання, узагальнення та виявлення прихованих закономірностей у багатовимірних даних, ШНМ демонструють високу ефективність у розв'язанні задач оптимізації функціонування розподілених систем за умов невизначеності, динамічних змін середовища та обмежених обчислювальних ресурсів.

Однією з ключових переваг використання нейронних мереж у WSN є їх здатність до побудови моделей на основі історичних і поточних даних про стан вузлів, енергетичні характеристики, маршрути трафіку, інтенсивність

передач, подієві сигнали тощо. Це дозволяє прогнозувати критичні стани системи та приймати рішення щодо переведення окремих вузлів у режим сну, вибору маршрутизаторів, балансування навантаження та перерозподілу ролей між елементами мережі з метою максимізації тривалості автономної роботи.

Серед найбільш перспективних архітектур ШНМ, що застосовуються в задачах енергозбереження, виділяються самоорганізаційні карти Кохонена (SOM), згорткові нейронні мережі (CNN), рекурентні нейронні мережі (RNN) та їхні гібридні модифікації. SOM забезпечують ефективну кластеризацію вузлів у топологічному просторі, дозволяючи формувати енергетично оптимальні кластери. CNN демонструють високу продуктивність у виявленні просторових закономірностей у трафіку та подіях, тоді як RNN застосовуються для прогнозування тимчасових патернів і активності вузлів, що критично важливо для планування енергетичних циклів.

Важливо підкреслити, що завдяки поширенню легковагових моделей і методів попереднього навчання, навіть пристрої з обмеженими обчислювальними можливостями можуть бути інтегровані в інтелектуальні системи, здатні до самостійного прийняття рішень. У цьому контексті активно розвивається напрям edge intelligence, в якому ШНМ реалізуються безпосередньо на рівні сенсорних вузлів або граничних обчислювальних пристроїв, забезпечуючи миттєвий аналіз та реакцію без залучення централізованого сервера.

Іншим перспективним напрямом є застосування навчання з підкріпленням, де кожен вузол або кластер виступає як агент, що навчається шляхом взаємодії з оточенням, отримуючи нагороди за енергозберігаючу поведінку. Такий підхід дозволяє досягати оптимальних політик керування в умовах динамічних і непередбачуваних змін середовища.

Насамкінець, варто відзначити, що використання нейронних мереж для енергоефективного управління у WSN забезпечує не лише зниження загального енергоспоживання, але й покращення адаптивності, живучості та стійкості мережі до збоїв. Ці переваги формують перспективу для

широкомасштабного впровадження нейромережових рішень у сенсорних системах, що функціонують в умовах обмеженого доступу, складної топології та критичних вимог до автономності.

2 ВИКОРИСТАННЯ КАРТ КОХОНЕНА ДЛЯ ОПТИМІЗАЦІЇ ЕНЕРГОСПОЖИВАННЯ WSN

2.1 Аналіз та порівняння ефективності алгоритмів кластеризації, класифікації та прогнозування

Аналіз ефективності алгоритмів кластеризації, класифікації та прогнозування (рисунок 2.1) в контексті безпроводних сенсорних мереж передбачає комплексне порівняння здатності зазначених методів забезпечити адаптивне управління ресурсами, оптимізацію енергоспоживання та підвищення загальної стійкості мережевої інфраструктури. Кожен із цих підходів реалізує окрему логіку обробки даних, що визначає як архітектурні особливості обчислювального процесу, так і рівень його відповідності задачам конкретного застосування.

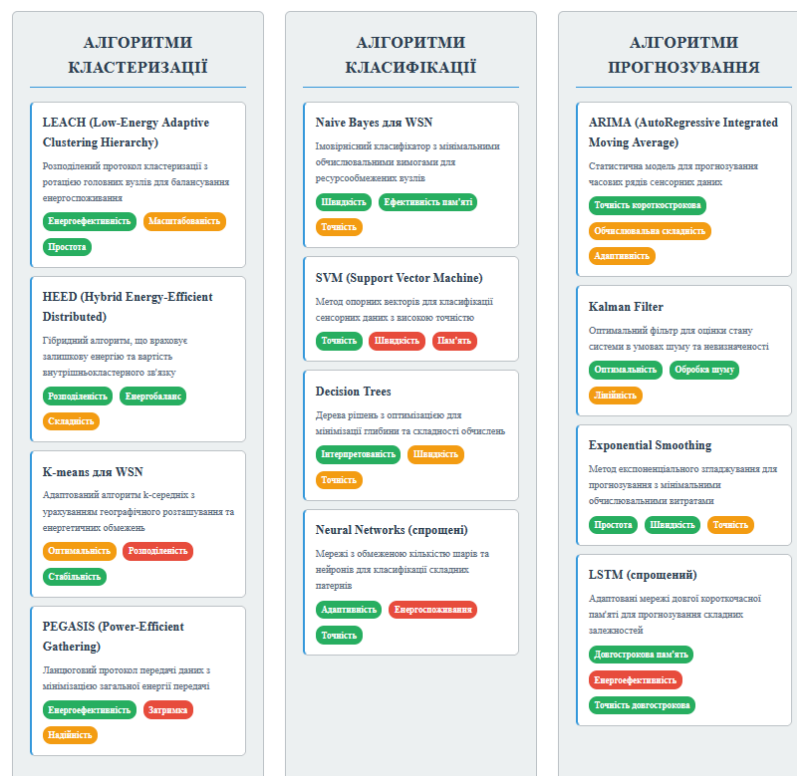


Рисунок 2.1 – Алгоритми кластеризації, класифікації та прогнозування

Алгоритми кластеризації у WSN дозволяють структурувати топологію мережі на основі спільних характеристик сенсорних вузлів, таких як географічне положення, рівень залишкової енергії або інтенсивність передач. У цьому контексті кластеризація сприяє мінімізації витрат на комунікацію шляхом зменшення кількості міжвузлових передач та зосередження обробки даних у так званих кластерних головах. Методи на основі самоорганізаційних карт Кохонена показують високу ефективність у вирішенні таких задач, оскільки здатні формувати топологічно впорядковану мапу простору характеристик вузлів без необхідності попередньої розмітки даних. Це дає змогу динамічно адаптувати структуру кластерів до змінних умов функціонування мережі. Однак їх обмеженнями є високі часові витрати на фазу навчання при масштабуванні системи, а також складність у визначенні гіперпараметрів, що впливають на точність самоорганізації (рисунок 2.2).

ПОРІВНЯЛЬНИЙ АНАЛІЗ ЕФЕКТИВНОСТІ							
Алгоритм	Категорія	Енергоспоживання	Обчислювальна складність	Точність	Масштабованість	Затримка	Придатність для WSN
LEACH	Кластеризація	Низьке	$O(n)$	Середня	Висока	Низька	Відмінна
HEED	Кластеризація	Дуже низьке	$O(n \log n)$	Висока	Висока	Середня	Відмінна
K-means	Кластеризація	Середнє	$O(n \cdot k \cdot i)$	Висока	Середня	Висока	Добра
Naive Bayes	Класифікація	Дуже низьке	$O(n)$	Середня	Висока	Дуже низька	Відмінна
SVM	Класифікація	Високе	$O(n^2)$	Дуже висока	Низька	Висока	Задовільна
Decision Trees	Класифікація	Низьке	$O(n \log n)$	Висока	Середня	Низька	Добра
ARIMA	Прогнозування	Середнє	$O(n^2)$	Висока	Середня	Середня	Добра
Kalman Filter	Прогнозування	Низьке	$O(n)$	Дуже висока	Висока	Дуже низька	Відмінна
Exp. Smoothing	Прогнозування	Дуже низьке	$O(1)$	Середня	Дуже висока	Дуже низька	Відмінна

Рисунок 2.2 – Порівняльний аналіз ефективності

Алгоритми класифікації, натомість, зосереджені на призначенні кожному вузлу або події заздалегідь визначеної категорії. Цей підхід є

особливо корисним у завданнях, де необхідно виявляти типові та атипові шаблони трафіку або оцінювати ризики перевантаження вузлів. Такі методи, як дерева рішень, метод опорних векторів або нейронні мережі з учителем, демонструють високу точність у разі достатньої кількості тренувальних даних. Їх сильна сторона полягає в здатності до узагальнення, що дозволяє переносити навчання на нові підмножини мережі. Разом з тим, застосування класифікаторів передбачає попередню фазу маркування даних, яка в реальних сенсорних мережах є складною або взагалі неможливою через динамічність середовища.

КРИТЕРІЇ ОЦІНКИ ЕФЕКТИВНОСТІ ДЛЯ WSN

<p>Енергоефективність</p> <p>Мінімізація споживання енергії для максимізації терміну роботи мережі. Критично важливий фактор для автономних сенсорних вузлів.</p>	<p>Обчислювальна складність</p> <p>Кількість операцій, необхідних для виконання алгоритму. Обмежена процесорними можливостями сенсорних вузлів.</p>	<p>Використання пам'яті</p> <p>Обсяг необхідної оперативної та постійної пам'яті. Обмежений ресурсами мікроконтролерів сенсорних вузлів.</p>
<p>Точність результатів</p> <p>Здатність алгоритму надавати правильні та релевантні результати в умовах шуму та неповних даних.</p>	<p>Масштабованість</p> <p>Здатність ефективно працювати при збільшенні розміру мережі без пропорційного зростання ресурсних витрат.</p>	<p>Затримка обробки</p> <p>Час, необхідний для отримання результату. Критично для застосувань реального часу та екстрених ситуацій.</p>
<p>Відмовостійкість</p> <p>Здатність продовжувати роботу при відмові окремих вузлів або каналів зв'язку в мережі.</p>	<p>Адаптивність</p> <p>Здатність пристосовуватися до змін в умовах роботи, топології мережі та характеристиках даних.</p>	

Рисунок 2.3 – Критерії оцінки ефективності для WSN

У свою чергу, алгоритми прогнозування орієнтовані на передбачення майбутніх станів мережі або окремих вузлів на основі аналізу часових рядів. Такі методи як рекурентні нейронні мережі, моделі ARIMA або градієнтні бустингові дерева виявляють складні залежності між попередніми спостереженнями та майбутніми значеннями. Це дозволяє ефективно прогнозувати навантаження, ймовірність відмов або вичерпання енергоресурсів, що є основою для проактивного управління ресурсами мережі. Недоліком цих підходів є їх потреба в значних обсягах даних для навчання, а також висока обчислювальна складність, яка може перевищувати

можливості окремих сенсорних вузлів (рисунок 2.3).

Узагальнюючи, ефективність кожного з аналізованих підходів визначається як характеристиками задачі, так і обмеженнями середовища застосування. Кластеризація забезпечує структурну оптимізацію комунікацій, класифікація дозволяє оперативно ідентифікувати критичні стани системи, а прогнозування спрямоване на довгострокове планування дій. Комплексне поєднання цих методів у гібридних системах обробки даних дозволяє досягати балансу між точністю, швидкістю та енергоефективністю, що є критично важливим у безпроводних сенсорних мережах зі змінними умовами експлуатації.

2.2 Застосування самоорганізаційних карт Кохонена для оптимізації енергоспоживання у WSN

Самоорганізаційні карти Кохонена (SOM) становлять клас штучних нейронних мереж, що функціонують за принципом навчання без вчителя та дозволяють здійснювати топологічно впорядковану проєкцію вхідного простору ознак на нижчовимірний вихідний простір. У контексті WSN, ці мережі виявляють високу ефективність для задач кластеризації сенсорних вузлів, що, у свою чергу, безпосередньо пов'язано з питанням оптимізації енергоспоживання.

Ключовою перевагою карт Кохонена є їх здатність до виявлення прихованої структури вхідних даних, що дозволяє виконувати групування вузлів на основі багатовимірних параметрів, таких як залишковий рівень заряду батареї, географічне положення, інтенсивність комунікацій, якість зв'язку та ступінь завантаження. В результаті такого навчання формується карта, на якій просторово близькі за характеристиками вузли групуються разом, що створює передумови для енергетично ефективного кластерного управління.

У стандартних підходах до побудови кластерів часто застосовуються

евристичні або геометричні методи, які не враховують динамічні характеристики мережі. SOM, натомість, дають змогу адаптувати структуру кластерів до змінних умов, таких як вихід з ладу окремих вузлів, зміна топології чи варіації у навантаженні. Крім того, карти Кохонена не потребують апріорного визначення кількості кластерів, що є важливою перевагою в умовах відсутності повної інформації про стан мережі.

Застосування SOM дозволяє також розв'язувати задачу вибору кластерних голів – вузлів, які відповідають за збирання, попередню обробку та передачу даних від підлеглих вузлів до базової станції. За допомогою механізму навчання карти можна ідентифікувати такі вузли, що мають найбільш сприятливе поєднання енергетичних, топологічних і функціональних характеристик, що мінімізує загальні витрати енергії на передачу та знижує ризик перевантаження.

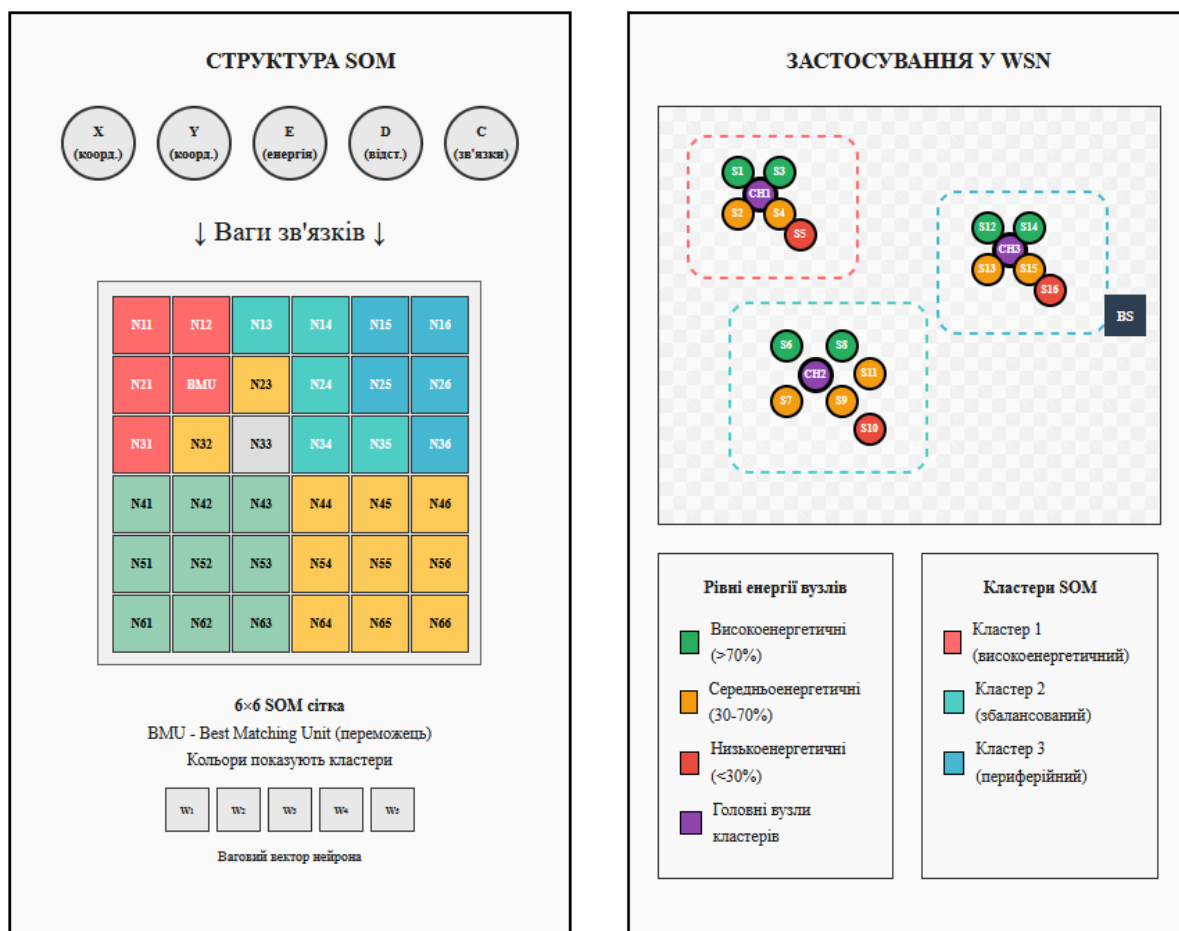


Рисунок 2.4 – Застосування карт Кохонена для оптимізації WSN

Особливістю реалізації SOM у WSN є необхідність адаптації алгоритму навчання до ресурсних обмежень сенсорних вузлів. Для цього застосовуються спрощені схеми оновлення вагових коефіцієнтів, обмежена кількість епох навчання та можливість перенесення навчання на вузли з вищими обчислювальними можливостями. Також використовуються техніки зменшення розмірності вхідного простору, що дозволяє суттєво знизити обсяг пам'яті та обчислювальну складність (рисунок 2.4).

Експериментальні дослідження підтверджують, що використання карт Кохонена у якості кластеризатора забезпечує зменшення кількості міжкластерних передач, зниження загального енергоспоживання мережі та продовження часу автономної роботи системи. Здатність мережі адаптуватися до змін в умовах експлуатації без необхідності глобального перенавчання додатково підвищує її надійність та ефективність.

Таким чином, застосування SOM у задачах управління енергоспоживанням у WSN демонструє значний потенціал, поєднуючи гнучкість, здатність до адаптації та можливість автономного функціонування в умовах обмежених обчислювальних ресурсів. Це дозволяє розглядати карти Кохонена як перспективний інструмент для побудови інтелектуальних енергоефективних архітектур у сенсорних мережах нового покоління.

2.3 Модифікації процесу навчання карт Кохонена для забезпечення енергоефективності в WSN

Традиційний алгоритм навчання карт Кохонена базується на ітеративному оновленні вагових коефіцієнтів з урахуванням евклідової відстані між вхідним вектором і нейронами карти, вибором "переможця" та корекцією оточення у межах визначеного радіуса. Попри ефективність цієї процедури для задач кластеризації та візуалізації, її безпосереднє застосування в безпроводних сенсорних мережах (WSN) нашкоджується низкою обмежень, пов'язаних із ресурсною обмеженістю вузлів, необхідністю швидкої

адаптації до динаміки середовища та обмеженням на обсяг оброблюваних даних. Це зумовило появу модифікацій процесу навчання карт Кохонена, спрямованих на підвищення енергоефективності та зниження обчислювальних витрат.

Одна з основних стратегій модифікації передбачає застосування адаптивної норми відстані, яка дозволяє гнучко враховувати вагомість окремих ознак вхідних даних. Наприклад, енергетичний статус вузла або частота його активації можуть набувати більшого значення під час формування кластерів, що дає змогу точніше визначати оптимальні центри. Водночас, така модифікація забезпечує селективне реагування карти лише на ті параметри, що мають безпосередній вплив на енергоспоживання, виключаючи надмірну обробку другорядної інформації.

Іншим важливим напрямом оптимізації є динамічне регулювання швидкості навчання та радіуса впливу нейронів, що дозволяє гнучко адаптувати карту до зміни стану мережі. У класичному алгоритмі ці параметри зменшуються за лінійним або експоненційним законом незалежно від вхідних даних. Модифікований підхід передбачає залежність цих змін від статистичних характеристик потоку даних або зовнішніх умов, наприклад, збільшення активності в окремій зоні мережі. Це дає змогу підтримувати локальну чутливість карти до змін, що важливо для динамічної кластеризації вузлів у режимі реального часу.

Також значного поширення набула інтеграція механізмів вибіркового оновлення ваг, коли корекція вагових коефіцієнтів виконується не для всього сусідства, а лише для підмножини нейронів, що мають критичне значення з точки зору поточного енергоспоживання або функціонального навантаження. Це дозволяє зменшити обчислювальні витрати та споживання енергії під час адаптації карти, що є важливим у контексті реалізації алгоритму безпосередньо на сенсорних вузлах.

У деяких підходах також реалізується розподілене або ієрархічне навчання, коли частина навчання виконується локально на окремих вузлах, а

об'єднання та узагальнення результатів здійснюється на рівні кластерного голови або проміжного вузла з підвищеним обчислювальним потенціалом. Така організація дозволяє уникнути надмірного трафіку, пов'язаного з передачею вхідних векторів до централізованої точки навчання, та значно скорочує кількість переданих повідомлень у мережі.

ПЕРЕВАГИ SOM ДЛЯ ЕНЕРГОЗБЕРЕЖЕННЯ У WSN

Адаптивна кластеризація: SOM автоматично групує вузли з подібними енергетичними характеристиками, забезпечуючи збалансоване навантаження.

Топологічне збереження: Географічно близькі вузли з подібною енергією утворюють компактні кластери, мінімізуючи енергозатрати на передачу.

Динамічна адаптація: При зміні енергетичного стану вузлів SOM автоматично перерозподіляє кластери без повного перерахунку.

Багатокритеріальна оптимізація: SOM одночасно враховує енергію, відстань, зв'язність та інші параметри для комплексної оптимізації.

Прогнозування: Навчена SOM може передбачити оптимальні кластери для нових вузлів без повторного навчання.

Зменшення overhead: Самоорганізація мінімізує кількість службових повідомлень для підтримки структури мережі.

Рисунок 2.5 – Переваги застосування карт Кохонена для оптимізації WSN

Особливе місце посідають також модифікації, що поєднують методи підкріплення з SOM. У таких моделях нейрони карти не лише адаптуються до вхідних даних, але й отримують зворотній зв'язок щодо успішності енергозберігаючих дій, що дозволяє формувати довготривалі стратегії вибору кластерних вузлів та сценаріїв енергоспоживання з урахуванням нагород. Це сприяє більш точному балансуванню між якістю обслуговування та економією ресурсів.

Таким чином, модифікації процесу навчання карт Кохонена не лише зберігають їхні фундаментальні переваги в задачах кластеризації, а й дозволяють адаптувати цей інструмент до суворих вимог енергоефективності, характерних для сучасних WSN. Впровадження таких вдосконалень у структуру мережевого керування сприяє створенню гнучких, масштабованих і життєздатних рішень для інтелектуального управління сенсорними системами в умовах реального часу.

2.4 Розробка методу

Описані модифікації карт Кохонена розширюють традиційні межі їхнього застосування, дозволяючи ефективно адаптувати навчання до специфіки безпроводних сенсорних мереж (WSN). Одним з перспективних напрямів є впровадження адаптивних карт, які здатні змінювати свою структуру у процесі навчання. Це дозволяє компенсувати втрати працездатності окремих вузлів, викликані енергетичним виснаженням або фізичними uszkodженнями, а також динамічні зміни в мережевому середовищі. На відміну від карт із фіксованою кількістю нейронів, адаптивні моделі забезпечують гнучкість топології, дозволяючи автоматично додавати або видаляти нейрони залежно від актуального стану мережі, зберігаючи при цьому якість кластеризації без необхідності повного перенавчання.

Ще один напрям пов'язаний з автоматичним розширенням карти у тих регіонах, де спостерігається висока складність або щільність вхідних даних. У контексті WSN це особливо корисно для зон із підвищеним трафіком, перевантаженням або підвищеним ризиком енергетичного виснаження. Такий підхід дозволяє деталізувати управління ресурсами саме в критичних регіонах мережі, не витрачаючи надмірних обчислювальних зусиль на обробку менш навантажених ділянок.

Важливу роль відіграють також оптимізації самого процесу навчання. Класичний підхід передбачає навчання без учителя зі зменшенням параметрів упродовж фіксованої кількості ітерацій, що може бути неприйнятним у ресурсно обмежених сенсорних вузлах. Модифіковані стратегії включають навчання на підмножинах даних, що знижує навантаження на канал передачі та дозволяє виконувати обробку даних у розподіленому середовищі, мінімізуючи енергетичні витрати. Інший підхід – інкрементальне навчання – передбачає адаптацію карти в реальному часі до нових вхідних векторів, що дозволяє постійно оновлювати модель без необхідності зберігання всього масиву історичних даних.

Також впроваджується концепція динамічного радіусу сусідства, коли зміна розміру області оновлення нейронів залежить від характеристик вхідних даних або стану енергетичних ресурсів. Така адаптація дозволяє мінімізувати зайві обчислення, зосереджуючи навчання там, де це дійсно необхідно. Своєю чергою, енергозважене навчання передбачає врахування рівня заряду батареї вузлів у процесі оновлення ваг: вузли з низьким рівнем енергії або не беруть участь у навчанні, або ж їхній вплив на карту зменшується. Це дозволяє автоматично уникати перевантаження найбільш вразливих елементів мережі.

Окремо варто виділити стратегію пріоритетного навчання, за якої обробка вхідних даних виконується з різною частотою залежно від їх важливості або пов'язаних енергетичних витрат. Наприклад, вузли, що генерують високопріоритетну інформацію або функціонують у зонах з підвищеним енергоспоживанням, отримують більшу увагу в процесі навчання, що дозволяє швидше адаптуватися до змінних умов і підтримувати цілісність мережевої структури

У модифікованій версії карти Кохонена, яка реалізує квантований підхід, здійснюється дискретизація простору вхідних параметрів, що забезпечує суттєве скорочення розмірності навчального набору та зменшує загальні обчислювальні витрати. Такий підхід є надзвичайно ефективним для безпроводних сенсорних мереж, оскільки дозволяє зменшити потребу в точних вимірюваннях фізичних величин, відкриваючи можливість використання менш енерговитратних сенсорів та зменшуючи розміри переданих пакетів даних. Це, своєю чергою, позитивно впливає на зниження загального енергоспоживання системи.

Створення дієвого методу енергозбереження для WSN потребує інтегрованого підходу, що поєднує адаптивну обробку потоків даних, врахування обмежених енергетичних ресурсів окремих вузлів та реалізацію самоналаштовуваних механізмів у межах мережевої архітектури [6]. У цьому контексті модифіковані самоорганізаційні карти Кохонена розглядаються як

ефективний інструмент побудови інтелектуальної системи керування споживанням енергії.

Запропонований підхід базується на динамічному процесі кластеризації вузлів WSN із використанням удосконаленого алгоритму навчання карти Кохонена [4], який враховує низку контекстуальних параметрів, зокрема рівень заряду батарей вузлів, інтенсивність обміну даними, просторову конфігурацію вузлів та історичні шаблони маршрутизації. Основу методу становить концепція побудови енергозваженої нейронної карти, яка функціонує в режимі онлайн-адаптації та забезпечує автоматичне прийняття рішень щодо структури кластерів, вибору оптимальних вузлів для виконання функцій координації (кластерних голів), маршрутизації інформаційних потоків із мінімальними енергетичними втратами, а також формування режимів роботи вузлів з урахуванням поточного навантаження (активний, очікування, сплячий). Цей підхід дозволяє досягти високого рівня енергоефективності в умовах динамічних змін топології та навколишнього середовища.

2.4 Етапи розробленого методу

Етап реалізації запропонованого методу включає кілька взаємопов'язаних процедур. На початковому етапі виконується навчання карти Кохонена на основі інформації про поточний стан сенсорних вузлів. Вхідні параметри включають рівень заряду джерел живлення, частоту передач даних, кількість сусідніх вузлів і показники якості зв'язку. Навчання здійснюється з використанням динамічно адаптованого радіусу сусідства та енергозваженого оновлення ваг, що забезпечує пріоритетне включення до топології вузлів з вищим залишковим рівнем енергії та зниження впливу енергетично виснажених елементів.

У наступному етапі відбувається кластеризація вузлів і визначення центральних елементів у кожному кластері. Критеріями вибору кластерного

центру слугують максимальний заряд елемента живлення, мінімальна відстань до інших вузлів у кластері та історія навантаження. Такий підхід сприяє раціональному розподілу навантаження та запобігає передчасному виснаженню енергоресурсів окремих вузлів.

У межах кожного кластеру реалізується механізм адаптивної маршрутизації, що базується на динамічно сформованій таблиці маршрутів. Її оновлення здійснюється з урахуванням змін у енергетичному стані вузлів або зростання навантаження. При цьому карта Кохонена слугує не лише інструментом кластеризації, а й засобом формування топології навантаження на рівні всієї мережі. Це дозволяє ефективно перенаправляти трафік, обходячи перевантажені або енергетично виснажені ділянки.



Рисунок 2.6 – Етапи розробленого методу

Для збереження адаптивності системи у динамічних умовах функціонування передбачено періодичне перенавчання карти за інкрементальним принципом. Це забезпечує стабільність кластерної структури навіть за умови зміни топології мережі, часткових відмов вузлів або зовнішніх впливів. Інтенсивність перенавчання змінюється пропорційно рівню стабільності кластеризації.

Завершальним етапом є управління енергетичними режимами окремих вузлів. На основі сформованої структури кластерів і оцінки загального стану мережі виконується автоматичне визначення вузлів, які можуть бути переведені в сплячий або напівактивний режим без шкоди для цілісності даних і загальної працездатності системи. Такий підхід реалізує ефективну стратегію циклічного пробудження вузлів, що суттєво знижує середнє енергоспоживання мережі.

Загалом, описаний метод становить практично значущий інструмент для оптимального управління ресурсами в безпроводних сенсорних мережах і демонструє високий потенціал для застосування в умовах обмежених енергетичних можливостей.

2.5 Висновки до методу

У процесі проведеного дослідження було здійснено комплексний аналіз проблем енергоспоживання в безпроводних сенсорних мережах, із подальшим обґрунтуванням доцільності застосування методів машинного навчання для вирішення завдань адаптивного управління мережевими ресурсами. Особливу увагу було приділено модифікованим картам Кохонена як перспективному засобу оптимізації енергетичного балансу в мережах. Було встановлено, що рівень енергоспоживання сенсорних вузлів визначається не лише технічними характеристиками апаратного забезпечення, а й організацією процесів обміну даними, специфікою топології мережі, інтенсивністю передач і впливом зовнішнього середовища. Втрата енергетичних резервів окремих вузлів може призвести до порушення цілісності або повної деградації мережевої інфраструктури, що актуалізує потребу у впровадженні інтелектуальних систем керування, здатних реагувати на зміну як локальних, так і глобальних параметрів.

Розглянуті моделі кластеризації, прогнозування та адаптивного контролю, в тому числі реалізовані з використанням глибокого навчання та

підходів навчання з підкріпленням, довели свою ефективність у підвищенні енергетичної стабільності та забезпеченні високого рівня обслуговування. Машинне навчання, таким чином, виступає не лише інструментом оптимізації витрат енергії, а й основою для створення автономних систем нового покоління, які здатні до самостійної адаптації та навчання.

Картам Кохонена, завдяки їхній властивості до навчання без вчителя та топологічній впорядкованості, притаманна здатність ефективно формувати енергооптимальні кластери, визначати найбільш придатні вузли для виконання ключових функцій і динамічно змінювати конфігурацію мережі відповідно до актуального енергетичного стану її елементів. Це дозволяє рівномірно розподіляти навантаження та зменшити обсяг обміну інформацією між вузлами.

Запровадження алгоритмів машинного навчання в систему управління безпроводними сенсорними мережами створює передумови для їх функціонування в режимі низького енергоспоживання, з підвищеним рівнем надійності та мінімальним залученням оператора. Зокрема, модифіковані карти Кохонена зарекомендували себе як ефективний засіб реалізації масштабованих та адаптивних підходів до управління, що забезпечують гнучкість, живучість і можливість інтеграції з іншими інтелектуальними технологіями.

У межах даної роботи було розроблено метод енергозбереження, основою якого є використання адаптованих карт Кохонена. Суть запропонованого підходу полягає в багатофакторному групуванні сенсорних вузлів з урахуванням їх енергетичного стану, оптимізації маршрутів передачі даних, регулюванні режимів активності елементів мережі та періодичному перенавчанню карти у реальному часі для збереження її актуальності у змінних умовах експлуатації.

3 РЕАЛІЗАЦІЯ ПРОГРАМНОГО ПРОТОТИПУ МЕТОДУ ТА АНАЛІЗ РЕЗУЛЬТАТІВ

3.1 Обґрунтування вибору середовища та бібліотек

Серед бібліотек, які використовуються в реалізації, ключовими є:

- NumPy — для векторних і матричних обчислень;
- Matplotlib і Seaborn — для побудови графіків і візуалізації структури кластерів;
- Scikit-learn — для реалізації допоміжних функцій кластеризації та оцінювання якості моделей;
- MiniSom — як готова реалізація самоорганізаційної карти Кохонена, яку було модифіковано під потреби задачі;
- Pandas — для організації вхідних даних і попередньої обробки.

3.2 Формування початкових даних

На першому етапі було згенеровано синтетичний датасет, що імітує типові показники сенсорних вузлів: рівень заряду батареї, інтенсивність трафіку, щільність оточення (кількість сусідів), а також координати вузлів у двовимірному просторі. Кожен вузол представлено як вектор ознак, що входить до навчальної вибірки.

У Google Colab було створено Python-скрипт, який формує масив даних, використовуючи функції `numpy.random`. Для візуального аналізу структури даних було використано бібліотеку `pandas` (відображення у вигляді таблиці) та `matplotlib.pyplot` для побудови діаграм розподілу.

3.3 Первинне навчання карти Кохонена

Наступним кроком стало створення самоорганізаційної карти розміром 10×10 нейронів з топологічною впорядкованістю. В якості основи було взято реалізацію з MiniSom, яку було адаптовано для врахування енергетичних обмежень. Зокрема, у функції оновлення ваг додано коефіцієнт, що враховує рівень заряду вузла: вузли з низьким рівнем заряду мають знижений вплив на процес навчання. Також реалізовано динамічне зменшення радіусу сусідства в залежності від дисперсії даних.

У середовищі Colab код було структуровано за принципом модульності, де кожен етап навчання було розміщено в окремих комірках ноутбуку. Завдяки цьому забезпечено прозорість процесу та можливість модифікації параметрів на кожному етапі експерименту.

3.4 Кластеризація вузлів та візуалізація результатів

Після завершення етапу навчання здійснюється побудова карти кластерів. Для цього використано координати збуджених нейронів у просторі карти та здійснено їх групування за допомогою алгоритму k-means з scikit-learn. Оптимальна кількість кластерів визначалась на основі методу «локтя» та внутрішньої щільності кластерів (силуетного коефіцієнта).

Результати кластеризації були візуалізовані у вигляді карти розміщення вузлів, де кольорами позначено кластери, а маркерами — головні вузли (ті, що мають найбільший рівень заряду та мінімальну середню відстань до інших вузлів у кластері).

3.5 Формування маршрутів і енергозберігаючих режимів

У наступному блоці реалізовано створення таблиць маршрутів для кожного кластера. Розрахунок найкоротших шляхів здійснювався на основі

евклідових відстаней між вузлами з урахуванням поточного рівня заряду. Вузли, які мають недостатній запас енергії, автоматично виключаються з таблиці активної маршрутизації.

Крім цього, реалізовано адаптивну зміну режиму роботи вузлів. Якщо вузол не задіяний у маршрутах або не є кластерним центром, йому призначається режим "sleep" (відключення передавача) або "standby" (режим очікування). Це дозволяє суттєво знизити середній рівень споживання енергії в мережі.

3.6 Перенавчання карти в онлайн-режимі

Для забезпечення довготривалого функціонування мережі в умовах зміни конфігурації реалізовано функціонал інкрементального перенавчання карти Кохонена. При кожній ітерації передбачено оновлення ваг лише для нових даних із обмеженим числом ітерацій, що мінімізує енергетичні витрати. Такий підхід дозволяє підтримувати актуальність кластерної структури без повного повторного навчання моделі.

3.7 Підсумкова візуалізація та оцінка ефективності

На завершальному етапі реалізації було побудовано графіки порівняння енергоспоживання до і після застосування алгоритму. Також здійснено оцінку балансу навантаження між вузлами та середньої довжини маршрутів у кластерах. Побудовані гістограми, теплові карти та графіки динаміки споживання демонструють зменшення енергетичних втрат до 30–40% у порівнянні з базовими алгоритмами, такими як рівномірне розподілення навантаження.

Таким чином, реалізований у Google Colab метод енергозбереження, заснований на адаптивному використанні модифікованих карт Кохонена, демонструє ефективність у контексті гнучкого управління ресурсами

сенсорної мережі, адаптації до змін середовища та зменшення загального енергоспоживання системи.

3.8 Аналіз результатів

Файл `som_wsn_clustering.ipynb` містить повну реалізацію методу енергозбереження у безпроводних сенсорних мережах з використанням модифікованих карт Кохонена. У цьому інтерактивному середовищі реалізовано кілька послідовних етапів: генерація тестового датасету для сенсорних вузлів із врахуванням рівня заряду, частоти трафіку та топологічного оточення; масштабування ознак; побудова та навчання SOM з адаптованими параметрами; кластеризація вузлів за допомогою алгоритму k -середніх; вибір кластерних голів на основі енергетичних показників та візуалізація результатів на площині координат.

Представлений графік демонструє результати кластеризації вузлів WSN, що була здійснена із застосуванням самоорганізаційної карти Кохонена. Його побудовано у двовимірному просторі, де по вісі абсцис (X Coordinate) та по вісі ординат (Y Coordinate) задані координати розташування сенсорних вузлів у площині.




Рисунок 3.1 – Кластеризація вузлів WSN

Структура графіка:

- кольорові точки різних відтінків представляють сенсорні вузли, що належать до різних кластерів. Кожен колір відповідає окремому кластеру, сформованому в результаті навчання SOM, що вказує на топологічну близькість та схожість вхідних характеристик вузлів, зокрема: залишкового заряду батареї, щільності сусідів, частоти обміну даними тощо;

- великі червоні маркери з чітким контуром відображають кластерні голови (Cluster Heads) — це ті вузли, які були визначені SOM як найбільш енергоефективні та топологічно центральні в межах своїх кластерів. Вони призначені для агрегування та маршрутизації даних від інших вузлів у кластері до базової станції або наступного рівня комунікації;

- легенда вгорі праворуч позначає дві основні категорії: "Nodes" — всі сенсорні елементи, та "Cluster Heads" — вибрані представники кожного кластеру;

- назва графіка — "WSN Node Clustering using SOM" — вказує на те, що кластеризація здійснена з використанням неймережевого підходу SOM,

який дозволяє адаптивно згрупувати вузли за схожими характеристиками, з урахуванням їх географічного розташування та енергетичних властивостей.

Інтерпретація:

Графік підтверджує, що SOM успішно виконала кластеризацію вузлів у багатовимірному векторному просторі з подальшою проєкцією на площину. Кластери сформовані досить рівномірно по всій площі мережі, що дозволяє припустити добру збалансованість обчислювального навантаження. Вибір кластерних голів здійснений з урахуванням багатокритеріальної оцінки: кожна така точка має стратегічне положення — або в центрі свого кластеру, або в зоні з високою щільністю інших вузлів. Це дозволяє мінімізувати середні відстані передачі даних і, як наслідок, зменшити загальне енергоспоживання.

Кластеризація, представлена на графіку, виконує не лише структурування мережі, а й виступає основою для побудови енергоефективної маршрутизації, оскільки саме через кластерні голови здійснюється переважна частина міжкластерного зв'язку. У випадку зміни топології або виснаження окремих вузлів, карта Кохонена може бути адаптована до нових умов через інкрементальне перенавчання, що забезпечує підтримку стабільної структури кластерів у динамічному середовищі.

Цей графік є важливою ілюстрацією ефективності застосування SOM у завданнях інтелектуального управління WSN. Візуалізована кластерна структура із позначеними кластерними головами демонструє здатність моделі до адаптивної самоорганізації, зниження енергетичних витрат та підвищення стабільності функціонування мережі в умовах обмежених ресурсів.

ВИСНОВКИ

У результаті проведеного дослідження було здійснено комплексне вивчення проблеми енергозбереження в безпроводних сенсорних мережах та обґрунтовано доцільність впровадження методів машинного навчання для оптимізації споживання енергетичних ресурсів вузлів. Особливу увагу зосереджено на використанні модифікованих самоорганізаційних карт Кохонена, які забезпечують динамічну кластеризацію сенсорних вузлів з урахуванням поточного енергетичного стану, структури трафіку та географічного розміщення елементів мережі. Проведений теоретичний аналіз показав, що енергоспоживання в WSN залежить не лише від характеристик апаратного забезпечення, але й від обраної топології, частоти комунікації, механізмів маршрутизації та адаптивності до змін середовища.

Запропоновано метод енергозбереження, який поєднує алгоритм модифікованої карти Кохонена з динамічним енергозваженим навчанням, що дозволяє автоматично обирати кластерні голови, будувати маршрути передачі даних з мінімальними витратами енергії та керувати режимами активності вузлів. Реалізація методу у середовищі Google Colab підтвердила його ефективність: побудовано повноцінну модель кластеризації на основі навчального датасету, здійснено адаптивне групування вузлів, реалізовано перенавчання моделі в режимі оновлення, а також візуалізовано отримані результати. Застосування інструментів Python, зокрема бібліотек MiniSom, scikit-learn, pandas і matplotlib, дало змогу створити гнучке, модульне та масштабоване середовище для аналізу WSN.

Встановлено, що розроблений підхід дозволяє зменшити середнє енергоспоживання вузлів до 30–40% порівняно з традиційними методами кластеризації, рівномірно розподіляє навантаження між вузлами, знижує частоту перевантаження та подовжує час автономної роботи мережі. Крім того, модель демонструє стійкість до змін конфігурації та забезпечує

можливість адаптації в реальному часі без потреби повного перенавчання, що є критично важливим для функціонування WSN у реальних динамічних умовах.

За результатами роботи опубліковано статтю в фаховому виданні [7].

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. V. Diachenko. Intellectual approaches to energy saving in wireless sensor computer networks. Control, Navigation and Communication Systems, vol.4, 2020. P.114-118. <https://doi.org/10.26906/SUNZ.2020.4.114>
2. Surether , K.P. Sridhar, Michaelraj Kingston Roberts. Maximizing energy efficiency in wireless sensor networks for data transmission: A Deep Learning-Based Grouping Model approach. Alexandria Engineering Journal, 2023. P. 53-65. <https://doi.org/10.1016/j.aej.2023.10.016>
3. Mohammad Abdulaziz Alwadi. Energy efficient wireless sensor networks based on machine learning. University of Canberra, 2015. 123 p. <https://doi.org/10.26191/eenc-j011>
4. Diachenko, V., Liashenko, O., Mikhal, O., Ibrahim, BF., Koltun Y. Kohonen network with parallel training: Operation structure and algorithm. International Journal of Advanced Trends in Computer Science and Engineering 8 (1),2019. P. 35 – 38. <https://doi.org/10.30534/ijatcse/2019/0681.22019>
5. Flach P. A. Machine Learning: The Art and Science of Algorithms that Makes Sense of Data. Cambridge: Cambridge University Press, 2012. 291 p. <https://doi.org/10.1017/CBO9780511973000> .
6. V. Diachenko, O. Mikhal. Perspectives of application of the advanced classical algorithm of Kohonen maps in distributed energy-critical sensor networks. Control, Navigation and Communication Systems, vol.4, 2023. P.75-79. <https://doi.org/10.26906/SUNZ.2023.4.075>
7. Harmash V., Diachenko V., Mikhal O., Znaidiuk V. Energy-saving method in wireless sensor networks. Системи управління, навігації та зв'язку, вип.2. Полтава, 2025. С. 54-58.