Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)
Кафедра Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти другий (магістерський)

Інтелектуальне керування конфігурацією енергомережі в умовах невизначеності за допомогою графових моделей
(тема)

Виконав:
здобувач другого року навчання,
групи СШІм-24-1
Таісія ШЕВЧЕНКО
(власне ім'я, прізвище)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)
Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)
Освітня програма Системи штучного інтелекту
(повна назва освітньої програми)
Керівник проф. Лариса ЧАЛА
(посада, власне ім'я, прізвище)

Допускається до захисту

Завідувач кафедри ШІ _____ Лариса ЧАЛА
(підпис) (власне ім'я, прізвище)

2026 р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук

Кафедра Штучного інтелекту

Рівень вищої освіти другий (магістерський)

Спеціальність 122 Комп'ютерні науки
(код і повна назва)

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

Освітня програма Системи штучного інтелекту
(повна назва)

ЗАТВЕРДЖУЮ:
Зав. кафедри _____
(підпис)
«_____» _____ 20 ___ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві Шевченко Таісії Сергіївні
(прізвище, ім'я, по батькові)

1. Тема роботи Інтелектуальне керування конфігурацією енергомережі в умовах невизначеності за допомогою графових моделей

затверджена наказом університету від 6 квітня 20 26 р. № 269Ст

2. Термін подання здобувачем роботи до екзаменаційної комісії 20 травня 20 26 р.

3. Вихідні дані до роботи Тестова енергомережа IEEE 14-bus, синтетичні часові ряди навантаження, графові моделі енергомереж, бібліотеки PyTorch Geometric, NetworkX та Python.

4. Перелік питань, що потрібно опрацювати в роботі
1) Аналіз предметної галузі та постановка задачі
2) Теоретичні основи графових нейронних мереж
3) Розробка моделі прогнозування та реконфігурації енергомережі
4) Практична реалізація, результати та порівняння методів

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Строк / термін виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	06.04.2026	виконано
2	Аналіз предметної галузі та літературних джерел	07.04.2026 – 10.04.2026	виконано
3	Дослідження методів прогнозування та	11.04.2026 – 15.04.2026	виконано
	графових нейронних мереж		виконано
4	Формалізація енергомережі у вигляді графа	16.04.2026 – 18.04.2026	виконано
5	Розробка архітектури GNN-моделі	19.04.2026 – 23.04.2026	виконано
6	Реалізація програмного прототипу системи	24.04.2026 – 01.05.2026	виконано
7	Проведення експериментів та навчання моделей	02.05.2026 – 07.05.2026	виконано
8	Аналіз результатів та реконфігурації мережі	08.05.2026 – 11.05.2026	виконано
9	Оформлення пояснювальної записки	12.05.2026 – 16.05.2026	виконано
10	Підготовка презентації та доповіді	17.05.2026 – 19.05.2026	виконано
11	Захист кваліфікаційної роботи	20.05.2026	

Дата видачі завдання 6 квітня 20 26 р.

Здобувач _____
(підпис)

Керівник роботи _____ проф. Лариса ЧАЛА
(підпис) (посада, власне ім’я, прізвище)

РЕФЕРАТ

Пояснювальна записка: 121 с., 31 рис., 2 дод., 19 джерел.

ГРАФОВІ МОДЕЛІ, ГРАФОВІ НЕЙРОННІ МЕРЕЖІ, ЕНЕРГОМЕРЕЖА, МАШИННЕ НАВЧАННЯ, ПРОГНОЗУВАННЯ НАВАНТАЖЕННЯ, РЕКОНФІГУРАЦІЯ МЕРЕЖІ, GAT, GCN, GNN, GRAPHSAGE, IEEE 14-BUS, NETWORKX, PYTHON, PYTORCH GEOMETRIC, SMART.

Об’єктом дослідження є процес прогнозування навантаження та реконфігурації енергомережі.

Предметом дослідження є графові нейронні мережі та графові моделі для аналізу й керування енергомережами.

Метою роботи є розробка графової моделі прогнозування навантаження та реконфігурації енергомережі на основі графових нейронних мереж.

Методами дослідження є теорія графів, методи машинного навчання, графові нейронні мережі, аналіз часових рядів та програмне моделювання у Python.

У роботі досліджено застосування графових нейронних мереж для прогнозування навантаження та реконфігурації енергомережі. Реалізовано моделі GCN, GraphSAGE та GAT у середовищі Python із використанням PyTorch Geometric. Побудовано графову модель IEEE 14-bus, проведено генерацію часових рядів навантаження, навчання моделей та аналіз аварійних ситуацій. Отримані результати підтвердили ефективність графових підходів для задач Smart Grid та аналізу стійкості енергомереж.

ABSTRACT

Master’s thesis contains: 121 pp., 31 fig., 2 ann., 19 references.

GAT, GCN, GNN, GRAPH MODELS, GRAPH NEURAL NETWORKS, GRAPHSAGE, GRAPHSAGE, IEEE 14-BUS, LOAD FORECASTING, MACHINE LEARNING, NETWORK RECONFIGURATION, NETWORKX, POWER GRID, PYTHON, PYTORCH GEOMETRIC, SMART GRID.

The object of the research is the process of load forecasting and power grid reconfiguration.

The subject of the research is graph neural networks and graph models for power grid analysis and control.

The purpose of the thesis is to develop a graph-based model for load forecasting and power grid reconfiguration using graph neural networks.

The research methods include graph theory, machine learning methods, graph neural networks, time-series analysis, and software simulation in Python.

The thesis investigates the use of graph neural networks for load forecasting and power grid reconfiguration. GCN, GraphSAGE, and GAT models were implemented in Python using PyTorch Geometric. A graph model of the IEEE 14-bus system was constructed, synthetic load time series were generated, models were trained, and emergency situations were analyzed. The obtained results confirmed the effectiveness of graph-based approaches for Smart Grid tasks and power system stability analysis.

ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів 8
Вступ 9
1 Аналіз предметної галузі та постановка задачі 12
1.1 Опис предметної галузі 12
1.1.1 Структура та принципи роботи енергомереж 13
1.1.2 Проблема прогнозування та реконфігурації при збоях 18
1.1.3 Використання штучного інтелекту в енергетиці 21
1.2 Аналіз існуючих методів прогнозування та керування навантаженням 25
1.2.1 Методи часових рядів (arima, sarima, prophet) 26
1.2.2 Методи машинного навчання та глибинного навчання 30
1.2.3 Обмеження класичних підходів в умовах невизначеності 34
1.3 Актуальність, новизна та очікувані результати 36
1.4 Постановка задачі дослідження 40
2 Теоретичні основи графових нейронних мереж 47
2.1 Основні поняття теорії графів 47
2.2 Типи графів у енергетичних системах 49
2.3 Архітектури графових нейронних мереж (gcn, graphsage, gat) 56
2.3.1 Graph Convolutional Network (GCN) 58
2.3.2 GraphSage 59
2.3.3 Graph Attention Network (GAT) 61
2.4 Порівняння архітектур і обґрунтування вибору 62
2.5 Математичні основи графових нейронних мереж 63
2.5.1 Асортативність 71
2.5.2 Гомофільність 72
2.5.3 Центральність 73
3 Розробка моделі прогнозування та реконфігурації енергомережі 76
3.1 Формалізація задачі у вигляді графа 76

3.2 Побудова графа на основі даних енергомережі 78
3.3 Алгоритм реконфігурації при збої 79
3.4 Архітектура gnn-моделі 82
3.5 Вибір функції втрат і оптимізатора 84
3.6 Навчання моделі та оцінка точності 85
4 Практична реалізація, результати та порівняння методів 88
4.1 Використані технології, середовище та підготовка даних 88
4.2 Архітектура програмного рішення 92
4.3 Отримані результати моделі (графи, прогноз, реконфігурація) 95
4.4 Аналіз стійкості моделі при відмовах вузлів 99
4.5 Порівняння gnn із класичними методами прогнозування 101
4.6 Переваги графових підходів у задачах енергетики 103
4.7 Можливі напрями вдосконалення системи 105
Висновки 108
Перелік джерел посилання 110
Додаток А Програмна реалізація системи 113
Додаток Б Відомість кваліфікаційної роботи 121

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

AI – Artificial Intelligence – штучний інтелект;

ARIMA – AutoRegressive Integrated Moving Average – авторегресійна інтегрована модель ковзного середнього;

GAT – Graph Attention Network – графова нейронна мережа з механізмом уваги;

GCN – Graph Convolutional Network – графова згорткова нейронна мережа;

GNN – Graph Neural Network – графова нейронна мережа;

GraphSAGE – Graph Sample and Aggregate – графова нейронна мережа з агрегацією сусідів;

MSE – Mean Squared Error – середньоквадратична помилка;

RMSE – Root Mean Squared Error – корінь із середньоквадратичної помилки;

Smart Grid – інтелектуальна енергомережа;

SMAPE – Symmetric Mean Absolute Percentage Error – симетрична середня абсолютна відсоткова помилка.

ВСТУП

Сучасний етап розвитку енергетичних систем характеризується стрімким зростанням складності енергомереж, інтеграцією відновлюваних джерел енергії, розвитком концепції Smart Grid та підвищенням вимог до надійності й безперервності електропостачання. Традиційні централізовані енергосистеми поступово трансформуються у складні динамічні структури, де кожен елемент мережі взаємодіє з великою кількістю інших компонентів, а стабільність роботи системи залежить від здатності швидко реагувати на зміну навантаження, аварійні ситуації та зовнішні впливи.

Особливої актуальності проблема стійкості енергомереж набула в умовах сучасних викликів, пов’язаних із фізичним пошкодженням інфраструктури, перевантаженнями мережі, нестабільністю генерації відновлюваних джерел енергії та зростанням рівня невизначеності у роботі енергетичних систем. У реальних умовах навіть локальне пошкодження окремої лінії електропередач або вузла може спричинити порушення зв’язності мережі, каскадні перевантаження та масштабні аварійні відключення. Це створює потребу у розробці інтелектуальних систем прогнозування та автоматизованого керування енергомережами, здатних не лише передбачати зміну навантаження, але й оперативно виконувати реконфігурацію структури системи у випадку аварійних ситуацій.

Класичні методи прогнозування, зокрема моделі часових рядів ARIMA, SARIMA або Prophet, демонструють ефективність у задачах аналізу часової динаміки, однак мають суттєві обмеження при роботі зі складними енергетичними системами. Основним недоліком таких підходів є те, що вони аналізують часові ряди ізольовано та не враховують топологічну структуру мережі. У результаті модель не здатна оцінити вплив сусідніх вузлів, зміну конфігурації системи або наслідки аварійних ситуацій для всієї мережі.

У зв’язку з цим особливого значення набувають графові методи аналізу даних та графові нейронні мережі (Graph Neural Networks, GNN). Графове подання дозволяє формалізувати енергомережу у вигляді структури, де вузли відповідають елементам системи, а ребра – фізичним зв’язкам між ними. Такий підхід значно точніше відображає реальні процеси передачі та розподілу електроенергії, оскільки враховує взаємозалежність між компонентами мережі та її топологічні характеристики.

Графові нейронні мережі є одним із найперспективніших напрямів розвитку штучного інтелекту у задачах аналізу складних структурованих систем. На відміну від традиційних нейронних мереж, GNN здатні виконувати обробку інформації безпосередньо на графах, агрегуючи дані від сусідніх вузлів та враховуючи структуру зв’язків між елементами системи. Це дозволяє одночасно аналізувати часову динаміку навантаження та просторові залежності у мережі, що є особливо важливим для енергетичних систем.

Використання графових нейронних мереж у задачах прогнозування навантаження відкриває нові можливості для створення адаптивних Smart Grid систем, здатних автоматично реагувати на зміну умов роботи мережі. Крім того, графовий підхід дозволяє реалізувати алгоритми реконфігурації енергомережі, які можуть відновлювати зв’язність системи після аварій шляхом активації резервних ліній електропередач або зміни структури графа.

У даній роботі досліджується можливість використання графових нейронних мереж для одночасного прогнозування навантаження та реконфігурації енергомережі в умовах невизначеності. Основою дослідження є тестова система IEEE 14-bus, на базі якої реалізується графова модель енергомережі, формуються часові ряди навантаження та моделюються аварійні ситуації.

У межах роботи виконано аналіз сучасних методів прогнозування навантаження, досліджено теоретичні основи графових нейронних мереж, реалізовано моделі GCN, GraphSAGE та GAT, а також проведено порівняння їхньої ефективності з класичними підходами часових рядів. Окрему увагу приділено моделюванню аварійних ситуацій, аналізу стійкості мережі та реалізації алгоритму реконфігурації після пошкодження елементів системи.

Практичне значення роботи полягає у створенні програмного прототипу інтелектуальної системи прогнозування та реконфігурації енергомережі, здатної працювати в умовах динамічної зміни топології та невизначеності даних. Результати дослідження демонструють перспективність використання графових нейронних мереж у задачах моніторингу, прогнозування та керування сучасними енергетичними системами.

Отримані результати можуть бути використані як основа для подальшого розвитку інтелектуальних Smart Grid платформ, систем автоматизованого диспетчерського керування та адаптивних енергетичних мереж нового покоління.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ ТА ПОСТАНОВКА ЗАДАЧІ

1.1 Опис предметної галузі

Енергетична галузь є однією з базових складових функціонування сучасної держави, оскільки саме вона забезпечує безперервну роботу промисловості, транспорту, житлово-комунального сектору, медичних установ, інформаційно-комунікаційної інфраструктури та інших критично важливих систем. Надійність електропостачання безпосередньо впливає на економічну стійкість країни, якість життя населення та безпеку функціонування суспільства в цілому. У сучасних умовах електроенергетика вже не розглядається лише як сукупність електростанцій, ліній передачі та споживачів. Вона перетворилася на складну багаторівневу кіберфізичну систему, у якій фізична інфраструктура тісно поєднується з цифровими засобами моніторингу, автоматизації, прогнозування та інтелектуального керування. Саме тому предметна галузь цього дослідження охоплює не лише класичні принципи функціонування енергомереж, а й сучасні підходи до їх аналізу в межах концепції Smart Grid.

Особливої актуальності ця тематика набуває в умовах зростання частки відновлюваних джерел енергії, появи розподіленої генерації, динамічної зміни профілів навантаження, зростання ролі активних споживачів та збільшення кількості зовнішніх і внутрішніх факторів невизначеності. У таких умовах енергомережа повинна не лише передавати електроенергію від джерела до споживача, а й адаптуватися до змінного режиму роботи, прогнозувати можливі перевантаження, виявляти аномальні стани та забезпечувати оперативну реконфігурацію у разі пошкоджень або аварій. Це виводить на перший план інтелектуальні методи обробки даних, зокрема засоби штучного інтелекту, здатні працювати з великими обсягами неоднорідної інформації та враховувати складні взаємозв’язки між елементами мережі.

1.1.1 Структура та принципи роботи енергомереж

Енергомережа являє собою складну розподілену систему, призначену для вироблення, передачі, розподілу та постачання електричної енергії кінцевим споживачам. У найзагальнішому розумінні її можна описати як сукупність взаємопов’язаних технічних об’єктів, що функціонують узгоджено в межах єдиного енергетичного простору. До складу такої системи входять джерела генерації, підстанції, лінії електропередач, розподільчі вузли, системи керування та захисту, а також споживачі різних категорій. На відміну від ізольованих технічних об’єктів, енергомережа функціонує як єдиний організм, у якому зміна стану одного елемента впливає на режими роботи інших. Саме ця взаємозалежність визначає складність її аналізу та керування [1].

Функціонально в структурі енергосистеми виділяють чотири основні компоненти: генерацію, передачу, розподіл і споживання. Генерація охоплює процес вироблення електричної енергії на електростанціях різного типу. Передача забезпечує транспортування електроенергії на значні відстані за допомогою високовольтних ліній. Розподіл відповідає за доставку електроенергії від магістральних мереж до локальних вузлів і кінцевих користувачів. Споживання завершує цей ланцюг, оскільки саме воно формує реальний попит на електроенергію і, відповідно, визначає режим функціонування всієї системи. Така послідовність «вироблення – передача – розподіл – споживання» є базовим принципом організації будь-якої енергомережі, однак у реальних умовах цей процес значно ускладнюється за рахунок резервування, двосторонніх потоків енергії та наявності активних споживачів.

Генерація електроенергії (рисунок 1.1) здійснюється на електростанціях, які перетворюють різні види первинної енергії на електричну. До традиційних джерел належать теплові електростанції, атомні електростанції, гідроелектростанції та теплоелектроцентралі.

Теплові електростанції виробляють електроенергію шляхом спалювання викопного палива, внаслідок чого утворюється теплова енергія, що перетворюється на механічну роботу турбіни, а потім на електричну енергію генератором. Атомні електростанції використовують тепло, що виділяється в ході ядерних реакцій, і є важливим джерелом базового навантаження.

Гідроелектростанції перетворюють енергію водного потоку, забезпечуючи відносно швидке регулювання режимів роботи. Теплоелектроцентралі одночасно виробляють електричну та теплову енергію, що робить їх важливим елементом міської інфраструктури. Поряд із цим дедалі більшого значення набувають відновлювані джерела енергії, зокрема сонячні та вітрові електростанції, а також біоенергетичні, геотермальні та припливні установки. Їх активне впровадження сприяє екологізації енергетики, однак водночас ускладнює процес балансування системи через нерівномірний характер генерації.

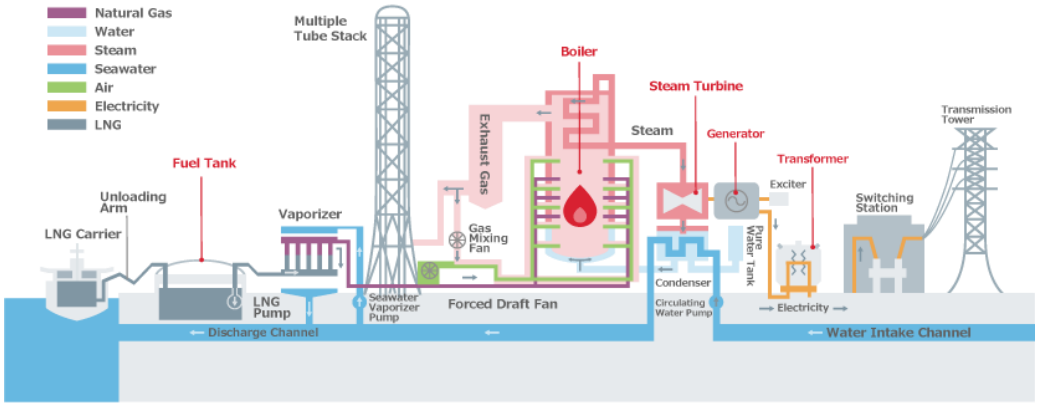


Рисунок 1.1 – Схема роботи електростанції

Після вироблення електроенергія надходить до системи передачі. Оскільки передавання електроенергії на великі відстані супроводжується втратами, важливим технічним принципом є підвищення напруги за допомогою трансформаторів. Чим вища напруга, тим менші втрати потужності під час транспортування. Саме тому електроенергія від

електростанцій спочатку подається до підвищувальних підстанцій, а далі передається магістральними високовольтними лініями до великих вузлів енергосистеми. На проміжних і приймальних підстанціях виконується поетапне зниження напруги до рівнів, придатних для подальшого розподілу. У цьому контексті підстанції відіграють не лише роль технічних пунктів перетворення параметрів електричної енергії, а й виступають важливими вузлами керування потоками потужності в мережі.

Розподіл електроенергії (рисунок 1.2) є завершальним етапом її доставки до кінцевого користувача. На цьому рівні функціонують розподільчі мережі середньої та низької напруги, які забезпечують електропостачання промислових об’єктів, підприємств, житлових будинків, установ соціальної сфери та транспортної інфраструктури. Особливістю сучасних розподільчих мереж є те, що вони дедалі частіше включають не лише пасивних, а й активних споживачів. Такий споживач не тільки використовує електроенергію, а й може генерувати її самостійно, наприклад за допомогою дахових сонячних панелей, а в певні моменти навіть передавати надлишок енергії назад у мережу. Цей процес суттєво змінює класичну односпрямовану модель руху енергії та формує нові вимоги до систем моніторингу і керування.

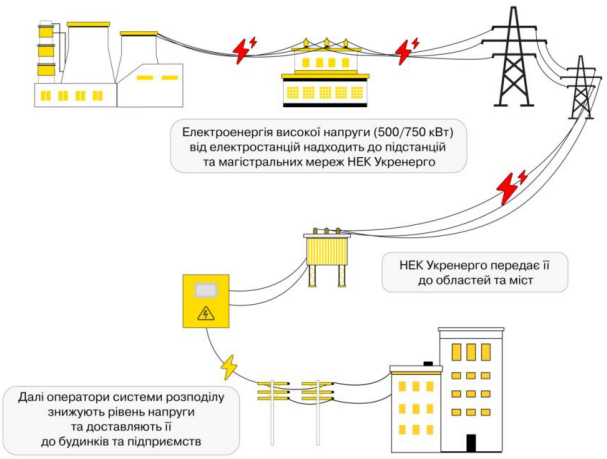


Рисунок 1.2 – Схема розподільної мережі з кінцевими та активними споживачами

З позиції математичного моделювання енергомережу доцільно розглядати як граф, де вершини відповідають окремим елементам системи, а ребра відображають фізичні або функціональні зв’язки між ними. Такий підхід є особливо корисним для дослідження складних енергетичних систем, оскільки дозволяє формально описати як топологію мережі, так і характеристики її окремих компонентів. У межах графового подання до вершин можуть належати електростанції, трансформаторні підстанції, вузли навантаження, центри споживання та точки приєднання розподіленої генерації. Ребра графа, своєю чергою, відповідають лініям електропередач і можуть характеризуватися довжиною, пропускною здатністю, електричним опором, допустимим навантаженням, втратами потужності та іншими параметрами. Завдяки цьому графова модель дає змогу не лише візуалізувати структуру енергомережі, а й виконувати аналіз зв’язності, шукати критичні вузли, моделювати потоки енергії та оцінювати наслідки пошкоджень.

У практичному сенсі графове подання особливо цінне для задач оцінювання стійкості та реконфігурації. Якщо в традиційному описі мережа розглядається як набір електротехнічних параметрів і схем з’єднання, то графова модель дозволяє перейти до формального аналізу структурних властивостей системи. Наприклад, у випадку пошкодження окремої лінії чи вузла можна швидко визначити, які частини мережі втрачають зв’язність, які альтернативні маршрути залишаються доступними та які елементи є критичними для підтримання функціонування всієї системи. Саме тому використання графових моделей є логічною основою для подальшого застосування графових нейронних мереж у задачах прогнозування та інтелектуального керування конфігурацією енергомережі.

Важливою характеристикою енергомережі є її топологія, тобто спосіб з’єднання окремих елементів між собою. У практиці побудови розподільчих мереж найчастіше розглядають радіальні, магістральні, кільцеві та більш складні мережні топології (рисунок 1.3). Радіальна схема передбачає, що

кожен споживач або група споживачів отримує живлення через окрему лінію. Така структура спрощує локалізацію пошкоджень, підвищує керованість і в багатьох випадках забезпечує достатній рівень надійності. У разі пошкодження однієї лінії відключення, як правило, стосується лише тієї ділянки, яка безпосередньо пов’язана з цією гілкою. Разом із тим, для підвищення стійкості в радіальних мережах часто передбачають резервні перемички між сусідніми ділянками або підстанціями.

Магістральна топологія є простішою та дешевшою з точки зору побудови, оскільки одна лінія може забезпечувати живлення відразу кількох споживачів або груп споживачів. Проте її недоліком є підвищена вразливість до пошкоджень: аварія на одній ключовій ділянці може призвести до одночасного знеструмлення значної кількості споживачів. Саме тому магістральні схеми доцільні переважно для менш відповідальних об’єктів або за наявності додаткового резервування. Кільцеві та мережні топології є більш складними, однак вони дозволяють реалізувати альтернативні маршрути передачі потужності. У разі пошкодження одного з елементів така структура підвищує шанси на збереження електропостачання за рахунок автоматичного або напівавтоматичного перемикання потоків. У контексті сучасних Smart Grid саме кільцеві й мережні топології становлять найбільший інтерес, оскільки вони краще пристосовані до реконфігурації та інтелектуального керування.



Рисунок 1.3 – Порівняння радіальної, магістральної та кільцевої топологій енергомережі

Окрім структури, критичне значення мають базові принципи функціонування енергомережі. Першим із них є баланс між генерацією та споживанням. Електроенергетична система повинна в кожен момент часу підтримувати відповідність між обсягом виробленої й спожитої електроенергії, інакше виникають коливання частоти, перевантаження або дефіцит потужності. Другим принципом є стабільність режиму роботи. Йдеться про здатність мережі підтримувати допустимі значення напруги, струму, частоти та навантаження навіть за наявності внутрішніх або зовнішніх збурень. Третім принципом є резервування, тобто наявність запасних потужностей, дублюючих ліній, резервних схем живлення та механізмів автоматичного перемикання, які забезпечують безперервність електропостачання у разі локальних збоїв. У сучасній енергетиці ці принципи більше не можуть реалізовуватися лише за рахунок традиційних ручних або жорстко запрограмованих механізмів керування. Зростання складності енергомереж робить необхідним використання інтелектуальних моделей, здатних динамічно оцінювати стан системи та підтримувати прийняття рішень у реальному часі [2].

1.1.2 Проблема прогнозування та реконфігурації при збоях

Однією з центральних проблем сучасної електроенергетики є забезпечення надійної роботи мережі в умовах динамічної зміни навантаження та можливих аварійних впливів. Для цього система повинна одночасно розв’язувати дві взаємопов’язані задачі: прогнозування майбутнього стану навантаження та реконфігурацію структури мережі в разі виникнення збоїв. Перша задача необхідна для того, щоб завчасно оцінити можливі перевантаження, локальні дефіцити потужності або дисбаланси між генерацією та споживанням. Друга задача виникає тоді, коли певна частина мережі втрачає працездатність і потрібно оперативно

знайти нову конфігурацію з’єднань, яка дозволить відновити живлення максимальної кількості споживачів без порушення технічних обмежень.

Прогнозування навантаження є базовою умовою ефективного керування енергомережами. У реальних умовах споживання електроенергії постійно змінюється під впливом великої кількості факторів. До них належать добові й сезонні коливання, температурні умови, режим роботи промислових підприємств, поведінка побутових споживачів, зміни у транспортному навантаженні, інтеграція електротранспорту, а також нестабільність виробітку відновлюваних джерел енергії. Усе це формує складну багатофакторну динаміку, яку неможливо адекватно описати простими лінійними залежностями. Якщо прогноз неточний, система може зіткнутися або з перевантаженням окремих ліній і вузлів, або з неефективним використанням ресурсів, коли резерви залучаються без реальної потреби. У великих енергосистемах навіть відносно невелика помилка прогнозування може призводити до значних економічних втрат або зростання ризику аварій [3].

Не менш важливою є задача реконфігурації мережі при збоях. Під реконфігурацією в цьому контексті слід розуміти зміну структури з’єднань між елементами мережі з метою підтримання або відновлення її працездатності. Така потреба виникає у випадках відмов вузлів, пошкодження підстанцій, обривів ліній електропередач, коротких замикань, критичних перевантажень або інших інцидентів, що порушують нормальний режим роботи. У найпростішому випадку реконфігурація може полягати в перемиканні резервної лінії або ізоляції пошкодженої ділянки. У складніших сценаріях вона охоплює аналіз усієї топології мережі, визначення множини допустимих варіантів перебудови, перевірку обмежень за пропускною здатністю ліній та оцінювання ризику подальших перевантажень. Таким чином, реконфігурація є не просто технічною операцією комутації, а інтелектуальною задачею оптимального вибору нового стану системи [2].

Ускладнення цієї задачі значною мірою пов’язане з невизначеністю. У сучасних енергосистемах невизначеність має багатокомпонентний характер. По-перше, вона проявляється у нестабільності навантаження, яке може різко змінюватися під дією погодних чинників, поведінкових моделей споживачів або надзвичайних ситуацій. По-друге, важливим джерелом невизначеності є відновлювані джерела енергії. Сонячні та вітрові електростанції мають залежний від природних умов характер генерації, через що їх внесок у загальний баланс потужності може суттєво змінюватися навіть протягом коротких часових проміжків. По-третє, на практиці система керування часто працює з неповними, зашумленими або затриманими даними, отриманими від сенсорів, лічильників, підстанційних контролерів або телеметричних систем. Це знижує точність оцінювання поточного стану мережі та ускладнює вибір оптимальної реакції.

Наслідки невизначеності в енергомережах можуть бути надзвичайно серйозними. Якщо система не встигає адекватно відреагувати на локальне перевантаження або втрату одного з елементів, це може запустити ланцюгову реакцію. Спочатку відмова одного вузла або лінії змінює потоки потужності в суміжних ділянках мережі. Далі ці ділянки можуть перейти в режим перевантаження, що спричиняє спрацьовування захисту та подальші автоматичні відключення. У результаті локальна аварія трансформується в каскадну відмову, яка охоплює дедалі більшу частину системи. У крайніх випадках це призводить до масштабного blackout, тобто повного або майже повного знеструмлення великої території. Саме тому завдання прогнозування та реконфігурації не можна розглядати окремо: точний прогноз дозволяє запобігати аварійним станам, а ефективна реконфігурація дає можливість мінімізувати їх наслідки [3].

В умовах України ця проблема має особливо гострий характер. Протягом останніх років енергетична інфраструктура країни зазнала численних масованих атак, унаслідок яких було пошкоджено значну кількість об’єктів генерації, передачі та розподілу. У таких умовах питання

стійкості енергомережі виходить далеко за межі звичайної технічної оптимізації та набуває стратегічного значення для енергетичної безпеки держави. Пошкодження окремих електростанцій, підстанцій або магістральних ліній створює необхідність дуже швидко перебудовувати маршрути передачі потужності, локалізувати зони ураження, зберігати живлення критичних споживачів та не допустити розвитку каскадних відмов. Наслідки таких інцидентів мають не лише енергетичний, а й соціальний, економічний та екологічний вимір, оскільки порушення електропостачання впливає на роботу лікарень, систем водопостачання, об’єктів зв’язку, транспортної інфраструктури та житлового сектору. У цьому контексті інтелектуальне керування конфігурацією енергомережі стає не просто засобом підвищення ефективності, а ключовою умовою забезпечення стійкості критичної інфраструктури.

Традиційні підходи до прогнозування та диспетчерського керування, хоча й відіграли важливу роль у розвитку електроенергетики, мають низку суттєвих обмежень. Більшість класичних моделей орієнтуються переважно на часові ряди споживання та генерації й не враховують просторово-топологічну структуру мережі. Вони можуть досить добре прогнозувати загальні тенденції, але не завжди здатні точно оцінити, як зміна стану в одному вузлі вплине на пов’язані з ним ділянки. Особливо це проявляється в ситуаціях, коли система переходить у нештатний режим, а локальні порушення швидко трансформуються в структурні проблеми всієї мережі. Саме тому для задач прогнозування і реконфігурації потрібні такі моделі, які одночасно враховують і часову динаміку, і топологічні взаємозв’язки між елементами енергосистеми [4].

1.1.3 Використання штучного інтелекту в енергетиці

Розвиток цифрової енергетики, поява інтелектуальних лічильників, телеметричних систем, промислового інтернету речей і платформ

оперативного диспетчерського моніторингу створили передумови для активного впровадження штучного інтелекту в задачі керування енергомережами. На відміну від традиційних алгоритмів, які здебільшого працюють за жорстко заданими правилами або спрощеними математичними моделями, методи штучного інтелекту дозволяють виявляти приховані залежності в даних, адаптуватися до змін середовища та формувати прогнози й управлінські рішення на основі складних багатовимірних ознак. У сфері енергетики це особливо важливо, оскільки поведінка системи формується під впливом великої кількості взаємопов'язаних чинників, частина з яких має нелінійний і стохастичний характер.

Одним із найпоширеніших напрямів застосування штучного інтелекту є прогнозування навантаження. Для цієї задачі використовуються як класичні алгоритми машинного навчання, так і сучасні глибинні нейронні мережі. Такі моделі аналізують історичні дані споживання, погодні показники, календарні особливості, сезонність, виробничі цикли та інші фактори, після чого формують прогноз майбутнього попиту. Перевага інтелектуальних моделей полягає в тому, що вони здатні працювати зі складними нелінійними закономірностями, які важко описати традиційними статистичними методами. У результаті підвищується точність прогнозування, а отже й ефективність планування генерації, балансування навантаження та управління резервами. Це особливо важливо для систем із великою часткою відновлюваних джерел енергії, де коливання генерації безпосередньо впливають на стабільність мережі.

Ще одним важливим напрямом є оптимізація розподілу ресурсів і режимів роботи енергосистеми. Штучний інтелект може застосовуватися для визначення оптимальних режимів завантаження обладнання, розподілу потоків потужності, координації роботи накопичувачів енергії, вибору моментів включення резервних потужностей та мінімізації втрат у мережі. У сучасних енергосистемах, де дедалі активніше використовуються системи зберігання енергії, локальні джерела генерації та гнучкі споживачі, подібні

інтелектуальні механізми стають основою ефективного керування. Вони дозволяють перейти від реактивного підходу, коли система лише реагує на події постфактум, до проактивного, коли можливі проблеми виявляються та компенсуються заздалегідь [3].

Важливе місце займає застосування штучного інтелекту у виявленні аномалій, несправностей та передаварійних режимів. Сучасні алгоритми класифікації, кластеризації та детектування відхилень можуть аналізувати потоки даних від сенсорів, лічильників, пристроїв релейного захисту та SCADA-систем з метою виявлення нетипових змін параметрів мережі. Це можуть бути аномальні коливання напруги, локальні перегріви обладнання, ознаки перевантаження ліній, нетипова поведінка споживачів або деградація технічного стану вузлів. На відміну від традиційного моніторингу, що часто ґрунтується на порогових правилах, ШІ-підходи здатні враховувати комплекс ознак і виявляти навіть ті сценарії, які не були жорстко описані заздалегідь. Завдяки цьому підвищується швидкість реагування на небезпечні стани та зменшується ризик розвитку серйозних аварій [1].

Суттєвим аргументом на користь практичної значущості цієї тематики є те, що інтелектуальні рішення вже реалізуються в реальних промислових та стартап-проєктах у сфері Smart Grid. Зокрема, компанія Heimdall Power розробляє IoT-рішення для високовольтних ліній електропередач, які дозволяють збирати дані про фактичний стан мережі в реальному часі та використовувати їх для підвищення ефективності експлуатації. Компанія Eos працює у сфері систем накопичення енергії, де інтелектуальні алгоритми можуть застосовуватися для оптимізації циклів заряджання й розряджання, а також для підтримання стійкості мережі при пікових навантаженнях. Стартап Helix Power пропонує рішення для компенсації різких дисбалансів потужності та стабілізації режимів роботи. Навіть без заглиблення в конкретну комерційну реалізацію цих продуктів видно, що сучасний вектор розвитку енергетики однозначно спрямований на

поєднання фізичної інфраструктури з інтелектуальними алгоритмами аналізу, прогнозування та керування [1].

Попри очевидні переваги штучного інтелекту, більшість традиційних AI-підходів у енергетиці все ж мають певні обмеження. Багато моделей працюють із табличними наборами ознак або часовими рядами й не враховують структурну природу самої енергомережі. Проте мережа є не просто сукупністю незалежних точок спостереження, а системою взаємозв’язаних вузлів, у якій стан кожного елемента залежить від сусідніх та від загальної конфігурації. Саме тому дедалі більшої ваги набувають графові моделі, що дозволяють явно описувати зв’язки між компонентами системи [3].

У цьому контексті графові нейронні мережі становлять особливий інтерес, оскільки вони поєднують здатність глибинного навчання виявляти складні закономірності з можливістю враховувати топологічну структуру мережі. На відміну від класичних часових моделей, GNN аналізують не лише еволюцію параметрів у часі, а й характер взаємодії між вузлами, локальні й глобальні властивості топології, наявність критичних зв’язків, ступінь зв’язності та потенційні маршрути реконфігурації. Саме ця особливість робить графові нейронні мережі особливо перспективними для задач інтелектуального керування конфігурацією енергомережі в умовах невизначеності. Вони здатні працювати з моделлю, у якій стан мережі формується не тільки часовими змінами навантаження, а й самою структурою зв’язків між елементами. Це відкриває можливість створення систем, які одночасно прогнозують розвиток навантаження, оцінюють ризик відмови, виявляють критичні вузли та пропонують ефективні варіанти реконфігурації після аварійних подій [5].

Таким чином, сучасна енергетика є предметною галуззю, у якій поєднуються висока структурна складність, динамічність режимів роботи, критична залежність від точності прогнозування та потреба в оперативній адаптації до аварійних впливів. Саме це обґрунтовує доцільність

застосування графових моделей і графових нейронних мереж для побудови інтелектуальної системи керування конфігурацією енергомережі в умовах невизначеності, що і становить основу подальшого дослідження.

1.2 Аналіз існуючих методів прогнозування та керування навантаженням

Проблема прогнозування навантаження та керування режимами роботи енергосистеми належить до ключових задач сучасної електроенергетики. Від точності прогнозу залежить ефективність планування генерації, розподілу потужності, використання резервів, зменшення втрат електроенергії, а також здатність системи своєчасно реагувати на перевантаження, аварійні режими та зміну конфігурації мережі. Історично для розв'язання таких задач використовувалися статистичні методи аналізу часових рядів, пізніше – алгоритми машинного навчання, а з розвитком обчислювальних ресурсів – методи глибинного навчання. Кожна з цих груп підходів має власні переваги, сфери застосування та обмеження. Однак для енергомереж, які функціонують у динамічному середовищі та мають складну просторову структуру зв'язків, цього часто виявляється недостатньо. Саме тому аналіз існуючих методів є необхідним етапом для обґрунтування подальшого переходу до графових моделей [6]. У загальному вигляді прогнозування навантаження можна подати як задачу знаходження відображення

$$\hat{y}_{t+h} = f(y_t, y_{t-1}, \ldots, y_{t-p}, x_t), \tag{1.1}$$

де $\hat{y}_{t+h}$ – прогнозоване значення навантаження на момент часу $t + h$;

$y_t, y_{t-1}, \ldots, y_{t-p}$ – попередні спостереження ряду;

x_t – набір додаткових ознак або зовнішніх факторів;

$f(\,)$ – модель прогнозування.

У класичних статистичних методах ця функція задається аналітично, у машинному навчанні апроксимується алгоритмом на основі ознак, а в глибинному навчанні – формується внаслідок багаторівневого нелінійного перетворення даних.

1.2.1 Методи часових рядів (ARIMA, SARIMA, Prophet)

Одним із найтрадиційніших підходів до прогнозування навантаження є аналіз часових рядів. Часовим рядом називають послідовність значень певної змінної, зафіксованих у впорядковані моменти часу. На відміну від звичайної статистичної вибірки, у часовому ряді порядок спостережень має принципове значення, оскільки поточні та майбутні значення часто залежать від попередніх. Саме тому час у таких задачах виступає не просто індексом, а одним із визначальних чинників аналізу. У задачах енергетики такими рядами можуть бути погодинне навантаження вузла, добове споживання електроенергії, змінення потужності генерації, рівень напруги або інші експлуатаційні показники [6].

Особливістю часових рядів є те, що їхні рівні, як правило, не є незалежними. Інакше кажучи, значення показника в поточний момент часу часто визначається попередніми значеннями цього ж показника. Крім того, часові ряди нерідко є нестаціонарними, тобто їх математичне сподівання, дисперсія або структура залежностей можуть змінюватися з часом. У прикладних задачах зазвичай виділяють кілька основних компонент часового ряду: тренд, сезонність, циклічні коливання та випадкову складову. Саме характер поєднання цих компонент визначає вибір конкретного методу моделювання.

У найпростішому вигляді часовий ряд можна представити як

$$y_t = T_t + S_t + C_t + \varepsilon_t \,, \tag{1.2}$$

де – T_t – трендова компонента;

S_t – сезонна складова;

C_t – циклічна складова;

ε_t – випадкова помилка.

У деяких випадках застосовується не адитивна, а мультиплікативна форма подання, якщо амплітуда сезонних коливань залежить від рівня ряду. Таке декомпозиційне представлення є зручним для первинного аналізу, але для прогнозування в енергетиці найчастіше використовують більш формалізовані статистичні моделі, зокрема ARIMA, SARIMA та Prophet.

Модель ARIMA є однією з базових статистичних моделей прогнозування часових рядів. Назва походить від трьох її компонент: авторегресії (AR), інтегрування (I) та ковзного середнього (MA). Авторегресивна частина описує залежність поточного значення від попередніх спостережень, інтегрована частина відповідає за приведення нестаціонарного ряду до стаціонарного вигляду шляхом диференціювання, а ковзне середнє враховує вплив помилок попередніх прогнозів. У загальному вигляді модель ARIMA(p, d, q) може бути записана так:

$$\phi(B)(1-B)^d y_t \; = \; \theta(B)_{\varepsilon_t}, \tag{1.3}$$

де B – оператор зсуву назад;

$\phi(B)$ – поліном авторегресії порядку p;

$(1-B)^d$ – оператор диференціювання порядку d;

$\theta(B)$ – поліном ковзного середнього порядку q;

ε_t – випадкова похибка.

Практично це значить, що майбутнє значення ряду оцінюється на основі минулих значень і минулих похибок. ARIMA добре працює для відносно стабільних часових рядів без вираженої складної сезонності, коли основна структура динаміки може бути відтворена через автокореляційні залежності [3].

Для енергетичних даних модель ARIMA може бути корисною, наприклад, у задачах короткострокового прогнозування навантаження окремого об’єкта за наявності достатньої кількості історичних спостережень і відносно стабільних умов функціонування. Її перевагами є математична визначеність, відносна інтерпретованість та добра придатність до аналізу рядів із вираженою авторегресивною структурою. Водночас ефективність ARIMA істотно знижується, якщо часовий ряд має сильну сезонність, різкі структурні злами, зовнішні збурення або нестабільну поведінку, характерну для сучасних енергосистем.

Модель SARIMA є розширенням ARIMA для випадків, коли часовий ряд містить сезонні закономірності. Для енергоспоживання така сезонність є типовою, оскільки навантаження часто має добові, тижневі та річні цикли. Наприклад, споживання електроенергії змінюється залежно від часу доби, дня тижня, пори року, погодних умов та режимів роботи підприємств. SARIMA дозволяє включити в модель як звичайні, так і сезонні авторегресивні та ковзні компоненти. Її загальний запис має вигляд:

$$\Phi(B^s)\phi(B)(1-B)^d(1-B^s)^D y_t = \Theta(B^s)\theta(B)_{\varepsilon_t}, \qquad (1.4)$$

де s – довжина сезонного періоду;

D – порядок сезонного диференціювання;

$\Phi(B^s)$ та $\Theta(B^s)$ – сезонні поліноми авторегресії та ковзного середнього.

У практичному застосуванні це показує, що модель здатна враховувати повторювані шаблони у часовому ряді, наприклад щоденні або річні піки споживання. Для задач електроенергетики це є важливою перевагою порівняно з ARIMA, проте SARIMA, як і ARIMA, все одно зосереджується насамперед на часовій динаміці одного ряду, а не на взаємозв’язках між вузлами мережі.

Окремої уваги заслуговує Prophet – модель прогнозування часових рядів, розроблена для автоматизованого врахування трендів, сезонності та

календарних ефектів. У порівнянні з класичними ARIMA-підходами Prophet зручніший для практичного використання у випадках, коли потрібно швидко побудувати надійний прогноз без глибокої ручної настройки параметрів. У моделі Prophet часовий ряд розкладається на кілька складових:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \ , \tag{1.5}$$

де $g(t)$ – тренд;

$s(t)$ – сезонна компонента;

$h(t)$ – вплив свят або нерегулярних подій;

ε_t – випадкова складова.

Такий підхід добре працює в задачах, де поведінка навантаження суттєво залежить від календарних факторів, святкових періодів, неробочих днів або інших наперед відомих подій. У системах електропостачання це може бути корисно для прогнозування попиту в міських мережах, адміністративних будівлях або комерційних об’єктах, де календарні ефекти дійсно відіграють помітну роль.

Спільною рисою всіх методів часових рядів є те, що вони прогнозують майбутні значення на основі попередніх спостережень. Саме в цьому полягає їхня сила і водночас обмеження. Вони добре працюють тоді, коли минула динаміка є достатньо інформативною щодо майбутньої, а загальні умови функціонування системи залишаються відносно стабільними. Проте в умовах невизначеності, різких збоїв, аварійних перемикань, зміни конфігурації енергомережі або появи нових вузлів ці методи можуть втрачати точність. Основна причина полягає в тому, що вони не враховують просторову структуру системи, тобто не описують явно залежності між елементами мережі. Кожен вузол фактично розглядається як окремий часовий ряд, хоча в реальній енергосистемі його стан безпосередньо

залежить від сусідніх вузлів, пропускної здатності ліній та топології всієї мережі [4].

Ще одним суттєвим недоліком статистичних моделей є чутливість до нестаціонарності даних. У класичному підході передбачається, що після відповідного диференціювання часовий ряд стає стаціонарним або принаймні близьким до стаціонарного. Проте в енергетиці це припущення часто порушується. Реальні дані можуть мати структурні злами, пов’язані з аваріями, бойовими пошкодженнями, включенням нових джерел генерації, погодними аномаліями або різкою зміною профілю споживання. У таких умовах моделі ARIMA, SARIMA та Prophet демонструють обмежену стійкість, оскільки базуються на припущенні відносної стабільності динаміки в межах історичних даних.

1.2.2 Методи машинного навчання та глибинного навчання

Подальший розвиток задач прогнозування навантаження був пов’язаний із впровадженням методів машинного навчання, здатних працювати зі складнішими залежностями, ніж класичні статистичні моделі. На відміну від підходів часових рядів, у яких структура моделі заздалегідь задається аналітично, алгоритми машинного навчання вчаться знаходити закономірності безпосередньо з даних. Це дозволяє враховувати не лише історичні значення навантаження, а й широкий набір додаткових факторів: температуру повітря, вологість, день тижня, пору року, тип споживача, характеристики обладнання, виробничий режим підприємства тощо. У контексті енергетики це суттєво розширює можливості моделювання, оскільки навантаження рідко визначається одним-єдиним фактором.

Найпростішим представником цього класу є Linear Regression. Лінійна регресія моделює залежність між цільовою змінною та набором вхідних ознак у вигляді лінійної комбінації:

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_n x_n, \quad (1.6)$$

де $\hat{y}$ – прогнозоване значення навантаження;

$x_1, x_2, \ldots, x_n$ – вхідні ознаки;

β_0 – вільний член;

$\beta_1, \ldots, \beta_n$ – параметри моделі.

Перевагою лінійної регресії є її простота, швидкість навчання та висока інтерпретованість. В енергетиці вона може бути корисною в задачах, де існує приблизно лінійний зв'язок між споживанням і зовнішніми факторами, наприклад температурою або виробничим навантаженням. Проте для складних часових рядів із нелінійними залежностями, змінною сезонністю та короткими інтервалами спостережень її можливостей часто недостатньо. Саме тому в більш складних сценаріях застосовуються потужніші алгоритми.

Серед класичних методів машинного навчання поширеними є Random Forest, SVM та XGBoost. Random Forest базується на ансамблі дерев рішень і здатний моделювати нелінійні взаємозв'язки між ознаками без необхідності жорстких статистичних припущень. У задачах прогнозування навантаження ця модель добре працює на табличних даних, де важливо врахувати комбінації погодних, календарних і технологічних параметрів. Її перевага полягає в стійкості до перенавчання та можливості оцінювання важливості ознак [5].

Метод SVM у задачах регресії дозволяє будувати прогнози, використовуючи гіперплощину з максимальним зазором, а за рахунок ядерних функцій – моделювати складні нелінійні залежності. Хоча SVM є потужним інструментом для малих і середніх вибірок, у великих задачах енергетичного моніторингу він може бути менш зручним через вищу обчислювальну складність і складність масштабування [8].

Алгоритм XGBoost, як одна з найефективніших реалізацій градієнтного бустингу, широко застосовується для табличних даних і часто

показує високу точність у прикладних задачах прогнозування споживання. Його перевага полягає у здатності моделювати складні взаємодії між ознаками та ефективно працювати навіть за наявності пропусків чи неоднорідності даних. Для задач короткострокового прогнозування навантаження це робить XGBoost одним із сильних базових підходів. Проте, попри високу якість прогнозу, ця модель так само працює переважно з вектором ознак і не враховує мережеву структуру енергосистеми явно.

З розвитком глибинного навчання особливу роль у прогнозуванні часових процесів почали відігравати рекурентні нейронні мережі, зокрема RNN, LSTM та GRU. Їх головна перевага полягає в тому, що вони спроєктовані саме для роботи з послідовностями, де важливий порядок спостережень. Базова RNN оновлює прихований стан відповідно до поточного входу та попереднього контексту:

$$h_t = \sigma(W_h h_{t-1} + W_x x_t + b), \tag{1.7}$$

де h_t – прихований стан у момент часу;

t, x_t – вхідний вектор;

W_h, W_x – матриці ваг;

b – зміщення;

σ – функція активації.

Така архітектура дозволяє накопичувати інформацію про попередні стани, однак на практиці класичні RNN страждають від проблем затухання або вибуху градієнта, що ускладнює моделювання довготривалих залежностей.

Для подолання цієї проблеми були запропоновані LSTM та GRU. Зокрема, LSTM-мережі використовують механізм керованої пам’яті через систему воріт, які визначають, яку інформацію зберегти, забути або передати далі. Завдяки цьому LSTM ефективно працює з довгими часовими залежностями, сезонними патернами та нелінійною динамікою. У задачах

енергетики LSTM часто застосовують для прогнозування навантаження в реальному часі, оскільки вона здатна враховувати як короткострокові коливання, так і довгострокові закономірності споживання. Глибоке навчання в цілому дає змогу будувати моделі, які адаптуються до нових даних та краще відтворюють складну поведінку системи порівняно з класичними лінійними моделями.

У спрощеному вигляді функціонування LSTM можна описати через набір керуючих рівнянь:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f), \tag{1.8}$$

$$i_t = \sigma(W_f[h_{t-1}, x_t] + b_i), \tag{1.9}$$

$$\underline{C_t} = tanh(W_c[h_{t-1}, x_t] + b_c), \tag{1.10}$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \underline{C_t}\ , \tag{1.11}$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o), \tag{1.12}$$

$$h_t = o_t \cdot tanh(C_t), \tag{1.13}$$

де f_t – forget gate;

i_t – input gate;

o_t – output gate;

C_t – стан комірки пам’яті;

h_t – вихідний прихований стан.

Незважаючи на суттєвий прогрес, методи машинного та глибинного навчання мають спільну фундаментальну рису: вони переважно працюють або з табличними даними, або з послідовностями. Іншими словами, об’єкт спостереження в таких моделях подається у вигляді вектора ознак чи

часової послідовності. Для багатьох задач цього достатньо, але не для енергомережі як складної системи взаємозв’язаних вузлів. Реальна електроенергетична система має виражену графову структуру, у якій навантаження, потоки потужності та наслідки аварій залежать не лише від локальної історії вузла, а й від його положення в мережі, сусідніх елементів, доступних маршрутів та загальної топології. Класичні ML- і DL-підходи не моделюють ці просторові залежності явно, а отже, втрачають частину критично важливої інформації. Саме в цьому полягає головна причина інтересу до графових моделей, які здатні поєднати часовий і просторовий аналіз у межах єдиного підходу.

1.2.3 Обмеження класичних підходів в умовах невизначеності

Попри широкий спектр існуючих методів прогнозування, класичні статистичні моделі, а також традиційні алгоритми машинного і глибинного навчання мають ряд обмежень, які стають особливо помітними в умовах невизначеності. У стабільних режимах вони можуть забезпечувати прийнятну або навіть високу точність прогнозу, однак сучасні енергосистеми функціонують у середовищі, де структура навантаження, режим генерації та конфігурація мережі можуть змінюватися дуже швидко. У таких умовах недостатньо просто передбачити наступне значення часового ряду – необхідно розуміти, як локальні зміни вплинуть на пов’язану з ними частину системи [10].

Першим ключовим обмеженням є ігнорування топології мережі. Більшість традиційних моделей розглядають окремий вузол або окремий вимірюваний показник ізольовано, не враховуючи фізичні зв’язки з іншими елементами системи. Проте в енергомережі жоден вузол не функціонує автономно: зміна режиму одного елемента впливає на навантаження сусідніх вузлів, на розподіл потоків потужності, на втрати в лініях та на стійкість системи загалом. Якщо модель не враховує цих

взаємозалежностей, вона не може адекватно описати реальну динаміку мережі.

Другим суттєвим недоліком є нестійкість до змін структури системи. Класичні моделі зазвичай навчаються на історичних даних у межах певної сталої конфігурації. Якщо в мережі відбувається аварійне відключення лінії, пошкодження підстанції, перемикання маршруту живлення або підключення нового джерела генерації, модель фактично стикається з новою системою, якої вона раніше “не бачила». У таких умовах прогноз, побудований на попередній конфігурації, уже не відповідає реальному стану мережі [6].

Третє обмеження пов’язане з низькою ефективністю в аварійних і кризових сценаріях. У періоди пікових навантажень, нестандартної поведінки споживачів, різких погодних змін, збоїв або каскадних відмов дані перестають відповідати звичайним статистичним шаблонам. У таких ситуаціях традиційні моделі часто демонструють суттєве падіння точності, оскільки вони орієнтовані на повторювані закономірності, а не на структурні злами. Це особливо критично для задач реконфігурації, де система повинна не просто спрогнозувати майбутнє значення, а запропонувати коректну реакцію на нову топологічну ситуацію.

Четвертим обмеженням є відсутність вбудованих механізмів адаптації до структурної невизначеності. Хоча деякі сучасні моделі можуть донавчатися або оновлювати свої параметри, більшість із них не мають природного механізму, який дозволяє працювати з динамічно змінним графом зв’язків. В енергомережі це є принципово важливим, оскільки рішення про реконфігурацію повинні прийматися не лише на основі часової історії, а й на основі поточного стану зв’язності, критичності вузлів і доступності альтернативних маршрутів. Саме тому класичні підходи, навіть якщо вони добре працюють у звичайних умовах, виявляються недостатніми для побудови інтелектуальної системи керування конфігурацією мережі.

Узагальнюючи проведений аналіз, можна стверджувати, що методи часових рядів, машинного навчання та глибинного навчання є важливими етапами розвитку засобів прогнозування навантаження в енергетиці. Вони забезпечили значний прогрес у точності прогнозування та автоматизації обробки даних, однак їхньою спільною слабкою стороною залишається відсутність явного урахування графової природи енергомережі. Саме ця обставина створює логічний перехід до наступного розділу, присвяченого графовим нейронним мережам, які можна розглядати як наступне покоління моделей для задач, де часові залежності невіддільні від просторової структури системи.

1.3 Актуальність, новизна та очікувані результати

Сучасні електроенергетичні системи перебувають у стані глибокої трансформації, яка зумовлена одночасною дією кількох взаємопов’язаних чинників. З одного боку, зростає загальна складність енергетичної інфраструктури через інтеграцію відновлюваних джерел енергії, розвиток розподіленої генерації, використання систем накопичення енергії та поступовий перехід до концепції інтелектуальних мереж Smart Grid. З іншого боку, підвищуються вимоги до надійності, гнучкості та автономності керування, оскільки енергомережа повинна не лише забезпечувати передавання електроенергії, а й оперативно адаптуватися до змін навантаження, появи нестабільних режимів, відмов окремих елементів та зовнішніх дестабілізуючих впливів. За таких умов традиційні методи аналізу й диспетчерського керування дедалі частіше виявляються недостатніми, особливо тоді, коли необхідно враховувати не лише часову поведінку окремих показників, а й топологічну структуру всієї мережі [11].

Актуальність дослідження визначається насамперед тим, що сучасна енергосистема вже не є жорстко детермінованою та відносно стабільною інфраструктурою. Вона перетворюється на динамічне середовище, у якому

режим функціонування формується під впливом великої кількості факторів: нерівномірного споживання, погодних умов, змін виробітку відновлюваних джерел, технічного стану обладнання, резервних перемикань, а також аварійних і кризових подій. Особливої ваги ця проблема набуває в умовах, коли енергетична інфраструктура працює під впливом додаткових загроз, а збереження стійкості мережі стає не лише технічним, а й стратегічним завданням. У такій ситуації критично важливо мати інструменти, здатні одночасно оцінювати майбутній стан навантаження, виявляти потенційно небезпечні конфігурації мережі та пропонувати ефективні рішення щодо її реконфігурації. Саме це робить тему дослідження своєчасною та практично значущою [7].

Ще одним аспектом актуальності є те, що більшість класичних методів прогнозування, навіть за високої точності в окремих локальних задачах, орієнтовані переважно на часові або табличні дані. Вони аналізують історичну динаміку навантаження, погодні чи календарні фактори, але не відображають повною мірою фізичну природу енергомережі як системи взаємопов’язаних вузлів і ліній. У реальних умовах навантаження одного вузла не можна розглядати ізольовано, оскільки його зміна впливає на сусідні елементи, на перерозподіл потоків потужності, на допустимість режимів і на загальну стійкість системи. Таким чином, необхідність переходу від «плоских» моделей до структурних підходів є закономірною відповіддю на зростання складності предметної галузі [7].

У цьому контексті особливий науковий і практичний інтерес становлять графові нейронні мережі. Їхня перевага полягає в тому, що вони дозволяють одночасно працювати з двома типами залежностей, критично важливими для енергомереж: часовими та просторовими. Якщо класичні моделі прогнозують переважно на основі історичних значень показника, то графові підходи дають змогу врахувати ще й конфігурацію зв’язків між вузлами, локальні та глобальні властивості топології, критичність окремих елементів, можливість альтернативних маршрутів живлення та зміни

мережевої структури після аварій. Саме ця властивість відкриває нові можливості для побудови гнучких систем прогнозування й інтелектуального керування в Smart Grid, де прийняття рішення повинно спиратися не лише на минулу динаміку, а й на поточний та прогнозований стан мережі як цілісного графа [12].

Наукова новизна роботи полягає в поєднанні графового моделювання енергомережі з задачами прогнозування навантаження та реконфігурації мережевої структури в межах єдиного інтелектуального підходу. Якщо в більшості традиційних досліджень ці задачі розглядаються окремо, то в межах цієї роботи вони об’єднуються в спільну модель, де прогноз майбутнього стану системи безпосередньо пов’язується з аналізом її стійкості та можливістю адаптивного відновлення зв’язності у випадку порушень. Такий підхід дозволяє перейти від статичного прогнозування окремих показників до комплексного аналізу поведінки всієї мережі. Новизна також полягає в тому, що для оцінки структурних властивостей мережі та її потенційної вразливості можуть бути використані графові метрики, зокрема центральність, гомофільність та асортативність, які дають змогу кількісно описувати критичність вузлів, характер зв’язків між ними та схильність мережі до локалізації або поширення збоїв. Це розширює класичне бачення прогнозної моделі та робить її ближчою до реальних задач енергетичної безпеки [7].

Практичне значення дослідження визначається тим, що результати роботи можуть бути використані як основа для створення програмних засобів підтримки прийняття рішень у системах моніторингу та керування енергомережами. Побудована модель потенційно придатна для аналізу поточного стану мережі, оцінки критичних вузлів, короткострокового прогнозування навантаження, виявлення ризику перевантажень і моделювання варіантів реконфігурації після відмов окремих елементів. У перспективі подібні рішення можуть бути інтегровані в компоненти Smart Grid, системи диспетчерського контролю, цифрові двійники енергетичної

інфраструктури або навчально-дослідницькі платформи, призначені для відпрацювання сценаріїв аварійного реагування. Таким чином, робота має не лише теоретичну, а й прикладну цінність, оскільки спрямована на підвищення стійкості та адаптивності сучасних енергомереж [15].

Очікувані результати роботи полягають у створенні формалізованої графової моделі енергомережі та розробці на її основі інтелектуального підходу до прогнозування і реконфігурації. Передбачається, що в межах дослідження буде отримано модель, здатну аналізувати поточний стан мережі, прогнозувати навантаження в окремих вузлах, виявляти ознаки потенційних збоїв, визначати критичні елементи структури та пропонувати шляхи відновлення зв'язності після локальних пошкоджень або відмов. Очікується також, що практична реалізація у вигляді програмного прототипу дозволить провести експериментальне порівняння графового підходу з класичними методами часових рядів і машинного навчання, оцінити точність прогнозування, адаптивність до зміни топології та стійкість моделі в умовах структурної невизначеності [16].

У більш формалізованому вигляді очікуваний ефект від застосування розробленого підходу можна подати через мінімізацію сукупної функції втрат:

$$L = \lambda_1 L_{pred} + \lambda_2 L_{rec} + \lambda_3 L_{stab} \ , \qquad (1.14)$$

де L_{pred} – характеризує помилку прогнозування навантаження;

L_{rec} – помилку або неефективність реконфігурації мережі після збою;

L_{stab} – міру втрати структурної стійкості мережі;

λ_1,λ_2,λ_3 – вагові коефіцієнти, що визначають відносну важливість кожного компонента.

Навіть якщо така цільова функція в остаточній реалізації буде модифікована, її подання в теоретичному розділі підкреслює головну ідею

дослідження: система повинна бути орієнтована не лише на точність прогнозу, а й на підтримання працездатності мережі як цілісної структури.

Отже, актуальність теми зумовлена об’єктивною потребою переходу до нових підходів керування енергомережами в умовах зростаючої складності та невизначеності, наукова новизна полягає в інтеграції графових методів із задачами прогнозування та реконфігурації, а очікувані результати спрямовані на створення адаптивної моделі, здатної підвищити точність прогнозування, стійкість мережі та ефективність реагування на збої [8].

1.4 Постановка задачі дослідження

Метою кваліфікаційної роботи є розробка інтелектуальної графової моделі прогнозування навантаження та реконфігурації енергомережі на основі методів машинного навчання і графових нейронних мереж, яка здатна враховувати часову динаміку споживання, топологічну структуру мережі та зміну її конфігурації у випадку відмов окремих вузлів або ліній. Така постановка мети відображає прагнення перейти від локального прогнозування окремих часових рядів до комплексного аналізу енергосистеми як взаємопов’язаної графової структури, у якій прогноз і реконфігурація повинні розглядатися як взаємодоповнювальні процеси [19].

Досягнення поставленої мети вимагає розв’язання низки взаємопов’язаних наукових і прикладних завдань. Передусім необхідно дослідити структуру сучасних енергомереж, принципи їх функціонування, основні режими роботи та чинники, що визначають стабільність і надійність енергосистеми. Це потрібно для того, щоб побудувати коректну предметну основу дослідження та забезпечити відповідність між реальною фізичною інфраструктурою й її математичною абстракцією. На цьому етапі мають бути проаналізовані особливості генерації, передачі, розподілу та споживання електроенергії, а також роль резервування, балансування

навантаження й стійкості системи в умовах нормальних та аварійних режимів.

Наступним завданням є аналіз існуючих методів прогнозування навантаження та керування режимами енергомережі. Йдеться як про класичні статистичні моделі часових рядів, так і про сучасні алгоритми машинного та глибинного навчання. Метою такого аналізу є не лише опис вже відомих підходів, а й виявлення їх обмежень у задачах, де важливо враховувати структурні взаємозв'язки між елементами мережі. Особлива увага має бути приділена проблемі того, що більшість традиційних моделей не адаптовані до роботи зі змінною топологією, не відображають явно мережеву зв'язність і втрачають ефективність у випадках аварійних порушень або нестандартних конфігурацій [8].

Подальшим кроком є формалізація енергомережі у вигляді графа. Для цього необхідно визначити, які характеристики повинні бути закладені у вершини та ребра моделі. Вершини мають відображати типи об'єктів енергосистеми, зокрема генератори, підстанції, вузли навантаження та споживачів, а також містити релевантні параметри, наприклад потужність, рівень навантаження, технічний стан або координати. Ребра повинні описувати фізичні зв'язки між елементами мережі та включати такі параметри, як довжина лінії, пропускна здатність, втрати потужності, опір або інші експлуатаційні характеристики. На цій основі має бути побудовано математичне подання мережі, зокрема матрицю суміжності або інший механізм опису графової структури, придатний для подальшого застосування GNN.

У загальному вигляді граф енергомережі можна подати як

$$G = (V, E, X), \tag{1.15}$$

де V – множина вершин;

E – множина ребер;

X – матриця ознак вузлів.

Якщо необхідно враховувати ознаки ребер, модель може бути розширена до вигляду

$$G = (V, E, X, W), \tag{1.16}$$

де W – містить ваги або характеристики зв’язків між вузлами.

Таке формальне подання є принципово важливим, оскільки саме воно забезпечує можливість переходу від описового аналізу енергосистеми до її обчислювального моделювання [8].

Окремим завданням є розробка алгоритму реконфігурації мережі при збоях. У межах цієї роботи реконфігурація розглядається як процес відновлення або оптимізації структури зв’язків після пошкодження вузлів чи ліній, що призвело до порушення нормального режиму роботи системи. Для цього потрібно забезпечити виявлення ізольованих компонентів, визначення критичних вузлів, оцінювання ступеня порушення зв’язності та пошук альтернативних шляхів передавання електроенергії. Важливо, щоб цей алгоритм не існував ізольовано від прогнозної моделі, а був інтегрований у загальну систему інтелектуального керування. Ідея полягає в тому, що прогноз навантаження має використовуватися не лише для оцінки майбутнього стану вузлів, а й для попередження потенційно небезпечних режимів та вибору більш стійких конфігурацій мережі.

Ще одним важливим завданням є проєктування архітектури графової нейронної мережі, придатної для розв’язання поставленої задачі. На цьому етапі необхідно обґрунтувати вибір конкретного типу GNN-архітектури, наприклад GCN, GraphSAGE або GAT, визначити механізми агрегації ознак сусідніх вузлів, спосіб урахування часової динаміки, структуру вихідного шару та підхід до навчання моделі. Вибір функції втрат, оптимізатора і критеріїв оцінювання також є невід’ємною частиною постановки задачі, оскільки саме вони визначають, яким чином модель буде наближатися до

бажаної поведінки. У разі прогнозування навантаження базовою цільовою функцією може бути, наприклад, середньоквадратична помилка

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2, \quad (1.17)$$

де y_i – реальне значення навантаження;

$\hat{y}_i$ – прогноз моделі.

Для оцінювання точності також можуть використовуватися метрики MAE, RMSE або MAPE, залежно від специфіки експерименту.

Завершальним етапом постановки задачі є реалізація програмного прототипу інтелектуальної системи та проведення комплексної експериментальної перевірки її ефективності в різних режимах функціонування енергомережі. На цьому етапі відбувається перехід від теоретичного аналізу графових моделей та архітектур графових нейронних мереж до їх практичного застосування у задачах прогнозування навантаження та реконфігурації енергосистеми. Саме практична реалізація дозволяє оцінити, наскільки запропонований підхід є придатним для роботи зі складними структурованими даними та чи здатна модель адаптуватися до зміни стану мережі в умовах невизначеності.

Для проведення експериментів необхідно сформувати набір даних, що відображає поведінку енергомережі в різних режимах роботи. Оскільки доступ до повномасштабних реальних даних енергосистем є обмеженим, у межах роботи допускається використання синтетично згенерованих часових рядів навантаження, побудованих на основі закономірностей, характерних для реального енергоспоживання. Такі дані повинні моделювати добову та сезонну зміну навантаження, випадкові коливання споживання, перевантаження окремих вузлів, нерівномірний розподіл потужності та інші фактори, що впливають на роботу енергомережі. Використання синтетичних даних є доцільним також через можливість контролювати

параметри експерименту та моделювати аварійні сценарії, які складно або неможливо відтворити на реальних об’єктах.

У межах практичної реалізації необхідно сформувати графову модель енергомережі, у якій кожен вузол описується набором ознак, а зв’язки між вузлами визначають структуру мережі. Як ознаки вузлів можуть використовуватися активна та реактивна потужність, величина навантаження, тип елемента системи, напруга або інші параметри, що характеризують стан вузла. Ребра графа повинні містити інформацію про фізичні характеристики ліній електропередач, зокрема їхню довжину, пропускну здатність або вагу зв’язку між вузлами. Така структура дозволяє моделі одночасно враховувати як часову динаміку зміни навантаження, так і топологічні особливості енергомережі.

Після підготовки даних виконується навчання графових нейронних мереж. У межах роботи доцільно дослідити декілька архітектур GNN, зокрема GCN, GraphSAGE та GAT, оскільки кожна з них має власні особливості обробки графових структур. Навчання моделей повинно проводитися на часових вибірках із подальшим прогнозуванням майбутнього стану мережі. При цьому важливим аспектом є оцінка здатності моделей узагальнювати інформацію та працювати зі зміною топології графа без необхідності повного перенавчання.

Особливу увагу необхідно приділити моделюванню аварійних ситуацій. У реальних енергетичних системах значна частина проблем виникає внаслідок пошкодження окремих ліній електропередач, перевантаження вузлів, втрати зв’язності між компонентами мережі або каскадного поширення аварій. Саме тому в межах дослідження необхідно реалізувати сценарії відключення окремих ребер або вузлів графа з подальшим аналізом того, як це впливає на структуру системи та результати прогнозування. Важливо не лише виявити факт втрати зв’язності, але й дослідити, чи здатна графова модель визначати критичні елементи мережі та адаптуватися до зміни її конфігурації.

Окремим етапом є реалізація алгоритму реконфігурації мережі після аварії. У межах цієї задачі система повинна аналізувати поточну структуру графа, визначати ізольовані компоненти та знаходити можливі шляхи відновлення зв’язності. Для цього можуть використовуватися алгоритми пошуку шляхів у графі, аналіз центральності вузлів або резервних зв’язків між компонентами системи. Реконфігурація повинна забезпечувати мінімізацію втрат навантаження та відновлення працездатності мережі після пошкодження окремих елементів. Таким чином, модель переходить від пасивного прогнозування до активного аналізу та підтримки прийняття рішень у задачах керування енергосистемою.

У процесі експериментальної перевірки необхідно виконати порівняння графових моделей із класичними методами прогнозування часових рядів, такими як ARIMA, SARIMA або Prophet. Подібне порівняння дозволяє оцінити не лише точність прогнозування, але й здатність моделей працювати в умовах зміни структури системи. На відміну від традиційних моделей часових рядів, графові нейронні мережі мають можливість враховувати просторові залежності між вузлами, що є особливо важливим для енергомереж, де стан одного елемента безпосередньо впливає на інші частини системи.

Оцінювання ефективності моделі повинно здійснюватися за допомогою набору кількісних метрик. Для задач прогнозування можуть використовуватися середньоквадратична помилка, середня абсолютна помилка та симетрична середня абсолютна відсоткова помилка. Для аналізу стійкості мережі важливими є показники зв’язності графа, кількість компонент після аварії, коефіцієнт відновлення навантаження, а також зміна центральності ключових вузлів після реконфігурації. Комплексне використання таких метрик дозволяє оцінити не лише точність прогнозування, але й ефективність системи з точки зору забезпечення стабільності енергомережі.

Об’єктом дослідження в цій роботі є процеси прогнозування навантаження та реконфігурації енергомережі в умовах невизначеності. Предметом дослідження є методи графового моделювання та графові нейронні мережі як інструмент інтелектуального аналізу, прогнозування і відновлення структури енергетичної системи після збоїв. Таке розмежування є важливим, оскільки об’єкт визначає загальну область дослідження та сукупність процесів, що вивчаються, тоді як предметом виступають конкретні математичні, алгоритмічні та програмні засоби, за допомогою яких здійснюється аналіз цих процесів.

Разом із тим постановка задачі передбачає певні обмеження. У межах роботи енергомережа розглядається у вигляді спрощеної графової моделі, яка відображає основні структурні та функціональні характеристики системи, але не охоплює всі фізичні аспекти електротехнічних процесів, які враховуються у професійних системах моделювання енергосистем. Основний акцент робиться саме на дослідженні топологічних залежностей між вузлами та аналізі поведінки графових нейронних мереж у задачах прогнозування і реконфігурації.

Крім того, реконфігурація мережі розглядається переважно як задача алгоритмічного відновлення зв’язності та перерозподілу навантаження після аварії. У роботі не моделюються всі особливості реального диспетчерського керування, такі як складні режими релейного захисту, економічна оптимізація генерації, частотне регулювання або детальна динаміка перехідних процесів. Проте таке спрощення є виправданим з наукової точки зору, оскільки дозволяє зосередити увагу саме на дослідженні принципової придатності графових нейронних мереж до розв’язання задач прогнозування, аналізу стійкості та реконфігурації енергомереж у сучасних умовах невизначеності.

2 ТЕОРЕТИЧНІ ОСНОВИ ГРАФОВИХ НЕЙРОННИХ МЕРЕЖ

У попередньому розділі було показано, що традиційні моделі прогнозування навантаження, побудовані на часових рядах або табличних ознаках, мають суттєві обмеження в задачах, де поведінка системи залежить не лише від значень параметрів у часі, а й від просторової структури зв’язків між її елементами. Для енергомереж це має принципове значення, оскільки кожен вузол функціонує не ізольовано, а в межах складної системи взаємопов’язаних об’єктів, де зміна стану однієї ланки може впливати на значну частину мережі. Саме тому для подальшого дослідження необхідно перейти до апарату теорії графів, який дозволяє формально описати енергосистему як структуровану мережу, а також розглянути основи графових нейронних мереж як класу моделей, що здатні навчатися безпосередньо на графових даних.

2.1 Основні поняття теорії графів

Теорія графів є одним із ключових розділів дискретної математики, який використовується для опису систем із взаємопов’язаними елементами. Для енергетичних систем графове представлення є особливо природним, оскільки енергомережа фактично складається з вузлів та ліній зв’язку між ними.

Формально граф задається як

$$G = (V, E), \tag{2.1}$$

де V – множина вершин, або вузлів;

E – множина ребер, які визначають зв’язки між вершинами.

Якщо вершини містять додаткові характеристики, наприклад навантаження, потужність або тип вузла, граф може бути поданий у вигляді

$$G = (V, E, X), \tag{2.2}$$

де X – матриця ознак вузлів.

Якщо також враховуються характеристики ребер, наприклад пропускна здатність або опір лінії, модель можна доповнити ще однією множиною або матрицею параметрів:

$$G = (V, E, X, W), \tag{2.3}$$

де W – множина або матриця ваг ребер.

Однією з важливих характеристик вершини є її степінь вершини. Для неорієнтованого графа степінь вершини визначається як кількість ребер, інцидентних цій вершині:

$$deg(v_i) = \sum_{j=1}^{n} a_{ij}, \tag{2.4}$$

де a_{ij} – елемент матриці суміжності.

У задачах енергетики вузли з високим ступенем можуть виступати критичними точками розподілу потужності.

Для неорієнтованого графа матриця суміжності є симетричною, тобто $a_{ij} = a_{ji}$. Для орієнтованого графа ця симетрія, як правило, порушується. Матриця суміжності є фундаментальною для обчислювальної роботи з графами, оскільки саме через неї можна формалізувати зв’язність мережі, будувати алгоритми пошуку шляхів, виявляти компоненти зв’язності та виконувати операції, які в подальшому використовуються у графових нейронних мережах.

У задачах енергетики важливо враховувати фізичні характеристики ліній, тому використовуються зважені графи. Вага ребра може відповідати довжині лінії, її опору, пропускній здатності або втратам потужності:

$$W = [w_{ij}], \tag{2.5}$$

де w_{ij} – вага зв’язку між вузлами.

Для подальшого спектрального аналізу графів і побудови графових нейронних мереж важливою є також матриця ступенів D, що має вигляд:

$$D_{ii} = \sum_{j=1}^{n} a_{ij}, \tag{2.6}$$

а на її основі визначається графовий лапласіан:

$$L = D - A. \tag{2.7}$$

Лапласіан графа використовується для аналізу зв’язності мережі, кластеризації вузлів та побудови графових згорткових операцій. У задачах енергетики це дозволяє переходити від простого опису структури мережі до аналізу її стійкості та топологічних властивостей.

2.2 Типи графів у енергетичних системах

Представлення енергетичних систем у вигляді графів (рисунок 2.1) є одним із найефективніших способів формалізувати складну структуру мережевого середовища, у якому численні компоненти взаємодіють між собою і спільно визначають стабільність, гнучкість та надійність електропостачання. Якщо в попередньому підрозділі були введені загальні поняття теорії графів, то в цьому підрозділі увага зосереджується на конкретних типах графових моделей, які використовуються для опису реальних енергомереж. Такий аналіз є важливим не лише з теоретичної точки зору, а й для подальшого вибору архітектур графових нейронних мереж, оскільки різні типи графів задають різні умови для передачі інформації, агрегації ознак та прогнозування стану системи.

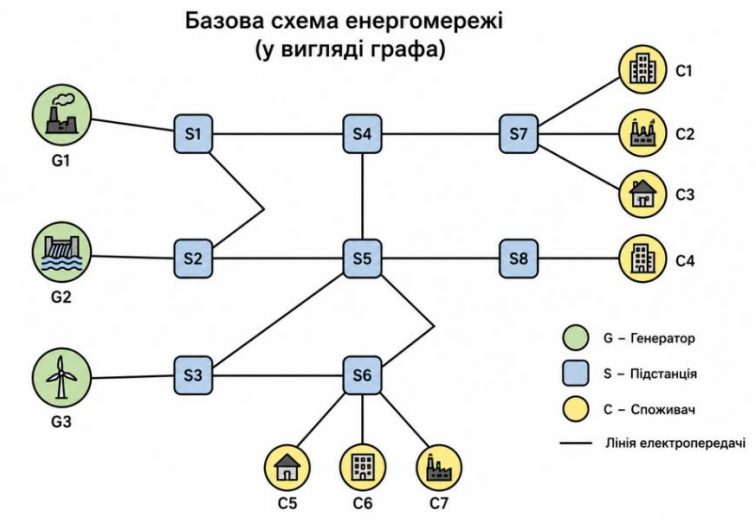


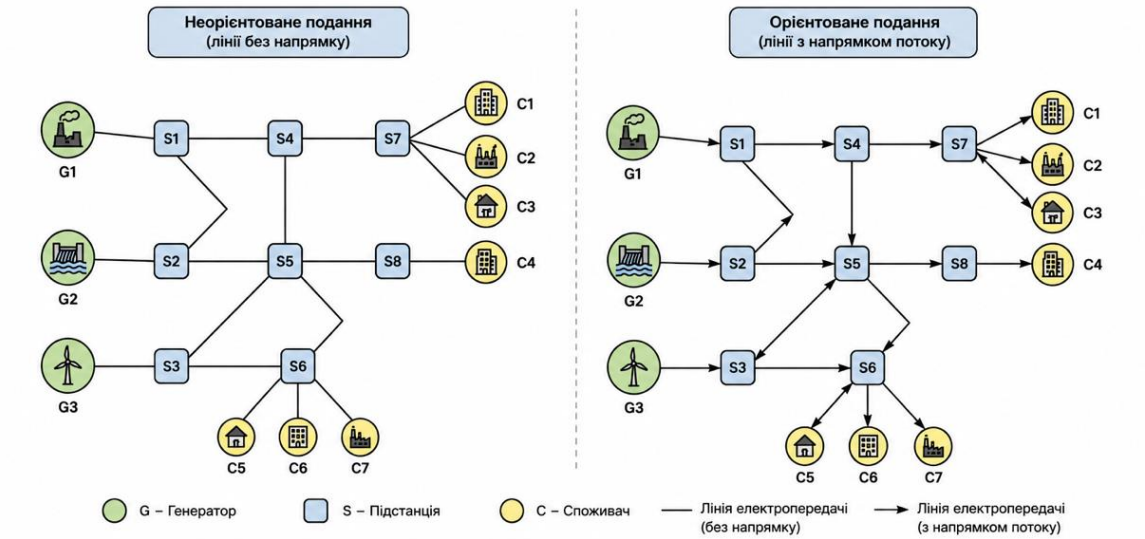
Рисунок 2.1 – Базова схема енергомережі, поданої у вигляді графа з генераторами, підстанціями та споживачами

Графи, що застосовуються в енергетиці, можуть класифікуватися за кількома ознаками: за наявністю або відсутністю напрямку зв’язків, за використанням ваг, за характером зміни структури в часі, за рівномірністю зв’язків між вузлами, за однорідністю або гетерогенністю типів елементів. У теоретичному сенсі це дозволяє описати енергосистему з різним ступенем деталізації, а в прикладному – вибрати таке подання, яке найкраще відповідає поставленій задачі: аналізу зв’язності, прогнозуванню навантаження, виявленню критичних вузлів або реконфігурації після збою. Важливо підкреслити, що не існує «єдино правильного» типу графа для всіх задач; корисність моделі визначається тим, наскільки добре вона відображає ті аспекти системи, які мають бути досліджені [17].

Однією з найважливіших класифікацій є поділ на орієнтовані та неорієнтовані графи (рисунок 2.2). У неорієнтованому графі ребро між двома вершинами – двосторонній або симетричний зв’язок, тобто з’єднання між вузлами без жорстко визначеного напряму. Таке подання є природним для загального опису топології енергомережі, коли нас цікавить передусім сам факт існування електричного з’єднання між вузлами. У багатьох

розподільчих мережах цей підхід є достатнім, особливо на етапі аналізу зв’язності, пошуку маршрутів, виявлення циклів або оцінки наслідків відключення окремих елементів. У неорієнтованому графі зв’язок між вузлами A і B є симетричним, тобто шлях від A до B тотожний шляху від B до A [17].

Водночас в енергетиці часто виникають задачі, де напрямок потоку має значення. У таких випадках доцільно використовувати орієнтовані графи, у яких кожне ребро задає зв’язок від однієї вершини до іншої у визначеному напрямку. Таке подання є корисним для моделювання передачі потужності від генератора до підстанції або від підстанції до навантаження, для аналізу основного напряму потоків енергії, а також для дослідження причинно-наслідкових ланцюгів у аварійних процесах. Якщо неорієнтоване подання краще відображає фізичну наявність зв’язку, то орієнтоване – його функціональний режим. Для задач GNN це теж має значення, оскільки орієнтованість змінює спосіб агрегації інформації між вузлами.



Критерій	Неорієнтоване подання	Орієнтоване подання
Ребра (лінії)	Без напрямку	З напрямком (від генератора до споживача)
Потік потужності	Не задається явно	Задається напрямком ребер
Застосування	Аналіз топології, зв'язності, надійності мережі	Розрахунок потоків потужності, оптимізація, керування
Кількість ребер	Менша або рівна (без урахування напрямку)	Може бути більшою (через різні напрямки)

Рисунок 2.2 – Порівняння орієнтованого та неорієнтованого подання енергомережі

Не менш важливими є зважені та незважені графи. У незваженому графі існування зв’язку між вузлами є єдиною суттєвою інформацією: ребро або є, або його немає. Така модель може бути корисною на ранньому етапі дослідження або тоді, коли потрібно проаналізувати лише загальну структуру мережі. Проте для енергетичних систем цього, як правило, недостатньо. Лінії електропередач мають довжину, опір, пропускну здатність, теплові обмеження, втрати потужності, вартість експлуатації й інші характеристики, які безпосередньо впливають на режими роботи. Саме тому енергосистеми доцільно моделювати у вигляді зважених графів, де вага ребра є функцією його фізичних параметрів. У спрощеному вигляді це можна записати як:

$$w_{ij} = f(R_{ij}, L_{ij}, C_{ij}), \tag{2.8}$$

де R_{ij} – опір лінії між вузлами i та j;

L_{ij} – її довжина;

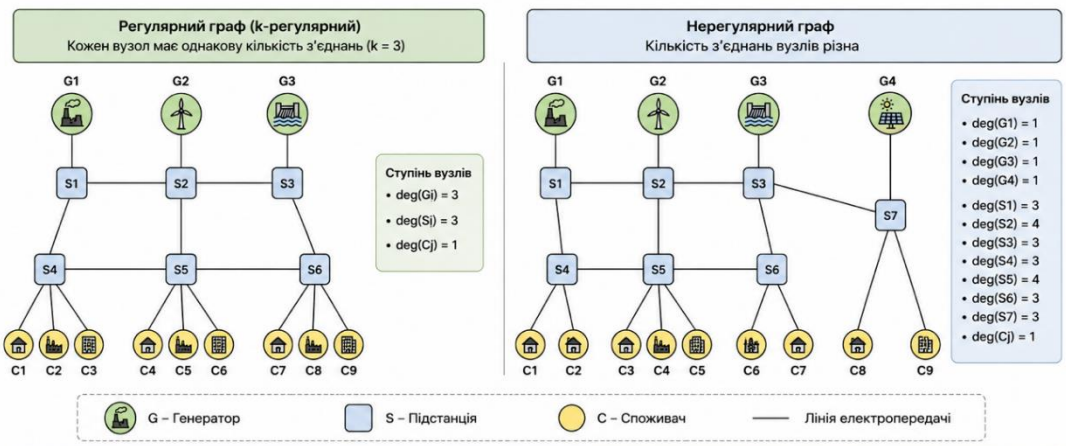
C_{ij} – пропускна здатність.

У більш складних моделях до цієї функції можуть додаватися показники втрат, ризику аварії або економічних витрат. Завдяки цьому зважений граф значно краще відображає фізичну природу енергомережі та є придатним для оптимізаційних і прогнозних задач [18].

Ще однією важливою класифікацією є поділ на статичні та динамічні графи. У статичному графі структура зв’язків між вершинами вважається незмінною в межах досліджуваного періоду. Такий підхід є зручним для аналізу сталих схем електропостачання або для базового дослідження топології мережі. Проте сучасні енергосистеми все частіше працюють у режимі структурної мінливості. Перемикання ліній, вихід із ладу окремих вузлів, підключення нових джерел генерації, резервування та аварійна реконфігурація змінюють граф мережі в часі. Саме тому дедалі більшого значення набувають динамічні графи, у яких змінюються або ознаки вузлів

і ребер, або сама структура зв’язків. Для задач прогнозування та реконфігурації це критично важливо, оскільки модель повинна враховувати не лише поточний стан мережі, а й її еволюцію після збоїв або керуючих дій.

З погляду структури зв’язків розрізняють також регулярні та нерегулярні графи (рисунок 2.3). Регулярний граф характеризується тим, що всі його вершини мають однаковий ступінь. Такі структури є зручними для математичного аналізу, проте в реальних енергосистемах вони майже не зустрічаються. Реальні мережі мають виражено нерегулярну структуру: частина вузлів є високо зв’язаними підстанціями або вузлами-хабами, тоді як інші мають лише один або два зв’язки. Саме така нерегулярність є принциповою характеристикою енергетичних систем і значною мірою визначає їхню стійкість, вразливість до збоїв та особливості поширення навантаження. Для графових нейронних мереж нерегулярність показує, що різні вузли отримують неоднаковий обсяг інформації від оточення, а отже їх роль у навчанні моделі є суттєво різною.



	Регулярний граф	Нерегулярний граф
Структура	Однакова кількість з'єднань для всіх вузлів одного типу	Кількість з'єднань вузлів різна
Приклад у енергомережі	Ідеалізована мережа з рівномірним розподілом навантаження та однаковою кількістю приєднань	Реальна мережа з різною кількістю ліній, вузлами з високою та низькою зв'язністю
Переваги	• Проста структура для аналізу • Передбачувана поведінка мережі	• Вища гнучкість і адаптивність • Можливість ефективного об'єднання різних типів вузлів
Недоліки	• Менш реалістична для реальних енергсистем • Обмежена різноманітність сценаріїв	• Складніший аналіз і моделювання • Нерівномірне навантаження на вузли
Застосування	Теоретичні дослідження, базові тести алгоритмів	Практичне планування, управління та оптимізація енергомереж

Рисунок 2.3 – Порівняння регулярного та нерегулярного графа на прикладі енергомережі

У контексті сучасної енергетики надзвичайно важливим є розмежування однорідних та гетерогенних графів (рисунок 2.4). Однорідний граф передбачає, що всі вершини та ребра належать до одного типу або принаймні розглядаються як такі в межах моделі. Подібний підхід може бути корисним для спрощеного теоретичного аналізу, проте він значно збіднює реальну картину. Енергосистема за своєю природою є гетерогенною: вона складається з генераторів, трансформаторних підстанцій, розподільчих пунктів, споживачів, накопичувачів енергії, різних типів ліній і навіть сенсорних або керуючих вузлів. У гетерогенному графі різні типи вершин і ребер можуть мати власні набори ознак та різну функціональну роль. Це робить таке подання більш реалістичним і більш корисним для задач прогнозування, виявлення критичних елементів та аналізу аварійних сценаріїв. Саме тому для енергетичних систем гетерогенний граф є значно більш природною моделлю, ніж однорідний.

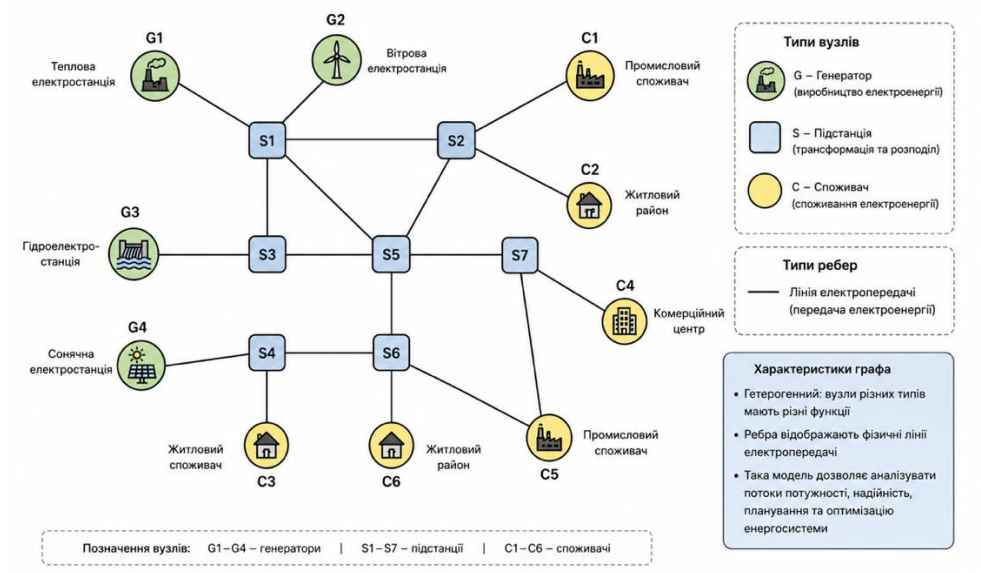


Рисунок 2.4 – Приклад гетерогенного графа енергосистеми з різними типами вузлів: генератор, підстанція, споживач

Окрім загальних класифікацій за властивостями зв’язків, для енергосистем принципово важливими є конфігураційні типи графів, що

відповідають різним топологіям мережі. Найпростішою і найпоширенішою є радіальна топологія, у якій кожен споживач або група споживачів отримує живлення по єдиному шляху від джерела чи підстанції. У термінах теорії графів така мережа є деревоподібною структурою без циклів. Її перевагами є простота експлуатації, зрозуміла схема потоків і менші капітальні витрати. Недоліком є висока вразливість до пошкоджень: вихід з ладу одного ребра може ізолювати цілу гілку мережі. Саме тому радіальні графи добре підходять для моделювання простих розподільчих мереж і є базовими для дослідження алгоритмів реконфігурації [18].

Другим важливим типом є кільцева топологія, у якій граф містить замкнений контур, що забезпечує альтернативні шляхи передавання енергії. У разі збою одна ділянка кільця може бути ізольована, а живлення відновлене іншим маршрутом. Це підвищує надійність мережі й робить кільцеві графи характерними для міських систем електропостачання. Водночас така структура ускладнює керування потоками й вимагає більш точного аналізу режимів [18].

Найбільш складними є сіткові або змішані топології, у яких між вузлами існує багато альтернативних маршрутів, а граф містить значну кількість циклів і паралельних шляхів. Такі структури характерні для великих міських або магістральних енергомереж і для концепції Smart Grid. Вони забезпечують високу стійкість та гнучкість, але водночас потребують складніших методів аналізу, оскільки зміна стану одного вузла може впливати на значну частину системи [18].

З точки зору сучасного дослідження енергомереж важливо зробити загальний висновок: реальна енергосистема найточніше описується як зважений, гетерогенний, динамічний і нерегулярний граф, а в багатьох сценаріях – ще й частково орієнтований. Вона є зваженою, тому що всі зв’язки мають фізичні параметри. Вона є гетерогенною, оскільки складається з різнотипних об’єктів. Вона є динамічною, бо її структура та параметри змінюються в часі. Вона є нерегулярною, оскільки ступінь

зв’язності вузлів суттєво відрізняється. Саме таке поєднання характеристик пояснює, чому класичні моделі часто виявляються недостатніми, і водночас обґрунтовує доцільність використання графових нейронних мереж, здатних працювати з даними подібної природи [18].

Таким чином, тип графового подання визначає, які саме властивості енергомережі буде відображено в моделі та які закономірності зможе виявити алгоритм навчання. Якщо базові поняття теорії графів формують математичний фундамент дослідження, то розуміння типів графів у енергетичних системах дозволяє перейти до наступного етапу – розгляду архітектур графових нейронних мереж, які реалізують роботу з такими структурами на практиці. Саме тому наступним логічним кроком є аналіз конкретних GNN-архітектур, зокрема GCN, GraphSAGE та GAT, і обґрунтування їхньої придатності для задач прогнозування та реконфігурації енергомережі.

2.3 Архітектури графових нейронних мереж (GCN, GraphSAGE, GAT)

Графові нейронні мережі об’єднують цілу групу архітектур глибинного навчання, призначених для обробки даних, представлених у вигляді графів. Їхня ключова перевага полягає в тому, що вони можуть враховувати не лише індивідуальні характеристики окремих вузлів, а й структурні залежності між ними. У задачах енергетики це є принципово важливим, оскільки стан будь-якого елемента мережі визначається не тільки його локальними параметрами, а й положенням у топології, кількістю і типом сусідніх вузлів, характеристиками ліній зв’язку та режимами роботи пов’язаних ділянок системи [18].

Незважаючи на різноманітність існуючих архітектур, більшість графових нейронних мереж працює за спільним принципом, який прийнято називати message passing (рисунок 2.5), тобто передаванням повідомлень між вузлами. На кожному шарі вузол отримує інформацію від своїх сусідів,

агрегує її певним способом, після чого оновлює власне представлення. Повторення цього процесу на кількох шарах дає змогу вузлу «бачити» дедалі ширший контекст графа. Саме на цьому механізмі базуються GCN, GraphSAGE та GAT, однак вони істотно відрізняються способом агрегації інформації, масштабованістю та здатністю враховувати неоднакову важливість сусідніх вузлів.

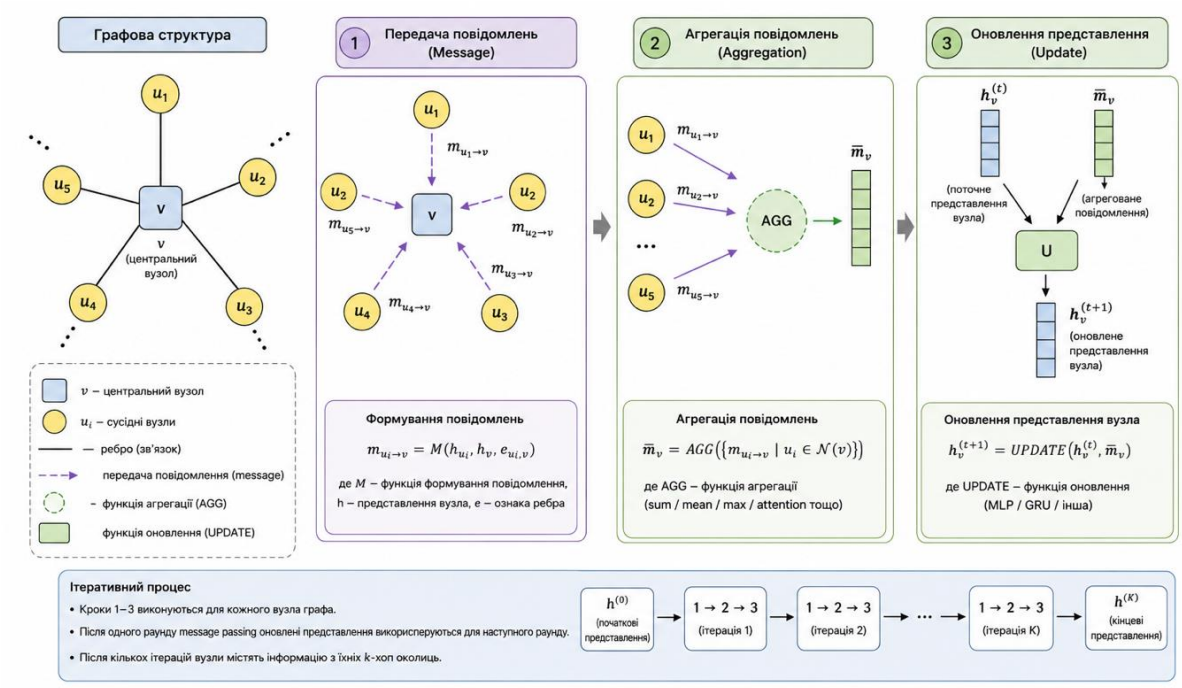


Рисунок 2.5 – Загальна схема message passing у графовій нейронній мережі

У загальному вигляді один крок message passing можна подати як:

$$h_v^{(l+1)} = \phi(h_v^{(l)}, AGG\ (\{h_u^{(l)} : u \in N(v)\})), \tag{2.9}$$

де $h_v^{(l)}$ – вектор ознак вузла v на l-му шарі;

$N(v)$ – множина його сусідів;

AGG – функція агрегації;

ϕ – функція оновлення.

Саме конкретний вибір функції агрегації та способу оновлення і визначає, до якого класу належить архітектура графової нейронної мережі.

2.3.1 Graph Convolutional Network (GCN)

Однією з найбільш відомих і базових архітектур графових нейронних мереж є Graph Convolutional Network. GCN переносить ідею згортки, добре відому з класичних згорткових нейронних мереж, на графові структури. Якщо в зображеннях згортка працює з регулярною сіткою пікселів, то в графах її аналогом стає агрегація інформації від сусідніх вузлів у локальному околі вершини. Таким чином, кожен вузол оновлює свої ознаки, використовуючи як власний вектор характеристик, так і інформацію від безпосередньо з'єднаних з ним вершин [15].

Ключовою ідеєю GCN є використання нормалізованої агрегації інформації з урахуванням структури графа. Для цього враховуються як зв'язки між різними вузлами, так і зв'язок вузла із самим собою. Такий підхід дозволяє уникнути ситуації, коли вузли з великою кількістю сусідів непропорційно домінують у процесі обчислень. У результаті ознаки вузлів спочатку проходять через лінійне перетворення, а потім агрегуються з урахуванням локального оточення з відповідною нормалізацією.

Суть цього підходу полягає в тому, що внесок кожного сусіда збалансовується залежно від кількості його зв'язків. Завдяки цьому GCN формує більш стабільні представлення вузлів і добре працює в задачах, де структура графа є відносно сталою [16].

У задачах енергетики GCN (рисунок 2.6) є природним базовим варіантом для моделювання мереж, топологія яких істотно не змінюється протягом періоду спостереження. Наприклад, при прогнозуванні навантаження на вузлах у межах фіксованої схеми енергопостачання ця модель здатна ефективно виявляти локальні просторові залежності між суміжними ділянками мережі [17].

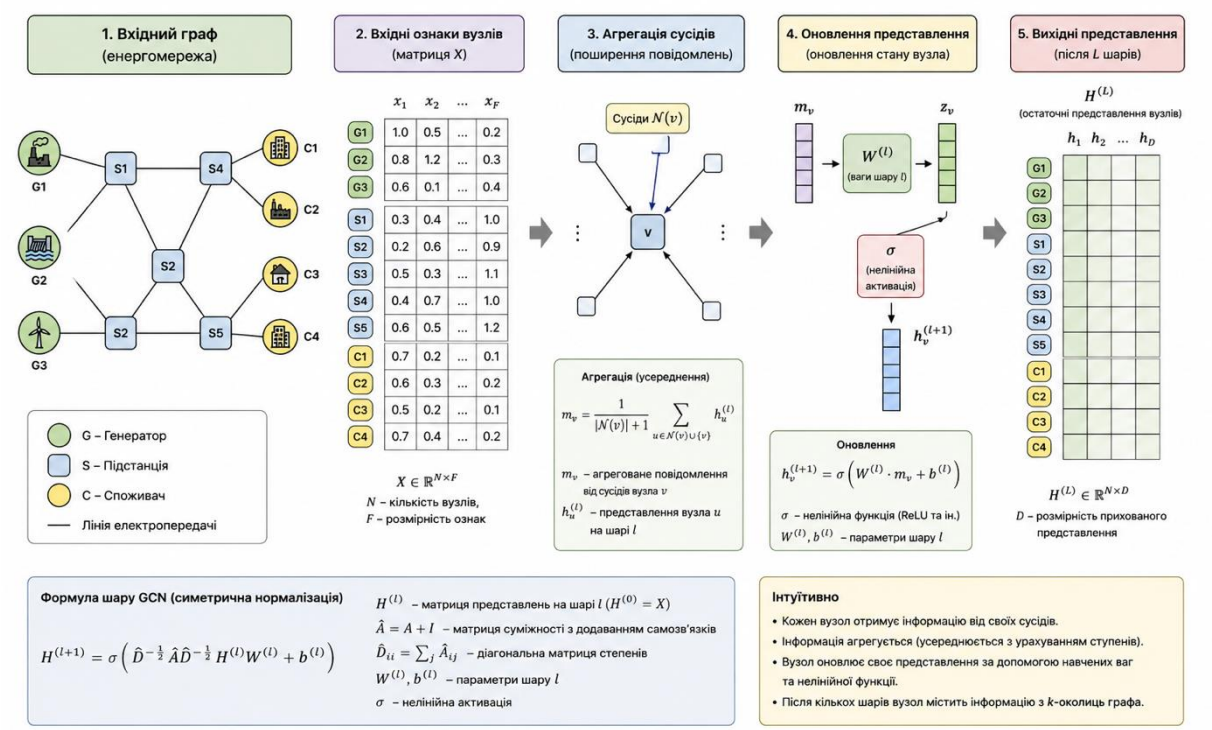
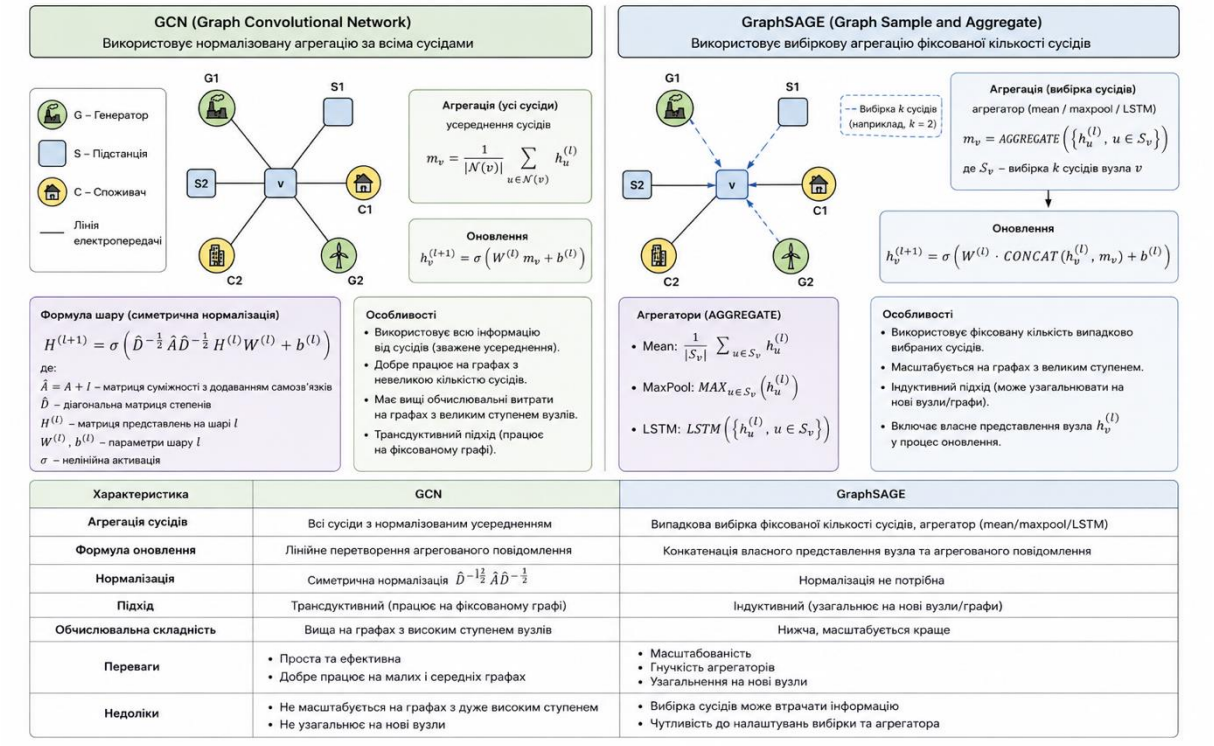


Рисунок 2.6 – Схема GCN

Водночас ця архітектура має низку обмежень. Зокрема, вона обробляє всі сусідні зв'язки досить рівномірно після нормалізації й не враховує їхню індивідуальну важливість. Це може бути проблемою для енергосистем, де різні лінії мають різний рівень критичності. Іншим недоліком є ефект надмірного згладжування: при збільшенні кількості шарів представлення вузлів можуть ставати надто схожими, що знижує здатність моделі розрізняти локальні особливості.

2.3.2 GraphSAGE

Архітектура GraphSAGE (рисунок 2.7) була розроблена для вирішення проблеми масштабованості графових моделей на великих даних. Її основна ідея полягає в тому, що замість використання всіх сусідів вузла модель вибірково використовує лише частину з них, після чого агрегує інформацію.



Характеристика	GCN	GraphSAGE
Агрегація сусідів	Всі сусіди з нормалізованим усередненням	Випадкова вибірка фіксованої кількості сусідів, агрегатор (mean/maxpool/LSTM)
Формула оновлення	Лінійне перетворення агрегованого повідомлення	Конкатенація власного представлення вузла та агрегованого повідомлення
Нормалізація	Симетрична нормалізація $\hat{D}^{-\frac{1}{2}}\hat{A}\hat{D}^{-\frac{1}{2}}$	Нормалізація не потрібна
Підхід	Трансдуктивний (працює на фіксованому графі)	Індуктивний (узагальнює на нові вузли/графи)
Обчислювальна складність	Вища на графах з високим ступенем вузлів	Нижча, масштабується краще
Переваги	• Проста та ефективна • Добре працює на малих і середніх графах	• Масштабованість • Гнучкість агрегаторів • Узагальнення на нові вузли
Недоліки	• Не масштабується на графах з дуже високим ступенем • Не узагальнює на нові вузли	• Вибірка сусідів може втрачати інформацію • Чутливість до налаштувань вибірки та агрегатора

Рисунок 2.7 – Порівняння GCN та GraphSAGE

Такий підхід є особливо важливим для великих графів, де кількість вузлів і зв’язків може бути дуже великою. Використання лише підмножини сусідів дозволяє значно зменшити обчислювальну складність і зробити можливим ефективне навчання з використанням міні-батчів.

У GraphSAGE нове представлення вузла формується шляхом поєднання його власних ознак із агрегованою інформацією від вибраних сусідів. На відміну від GCN, ця архітектура допускає використання різних способів агрегації, зокрема усереднення, рекурентні підходи або операції типу pooling. Це забезпечує більшу гнучкість у моделюванні локального оточення вузла [17].

Для енергетичних систем GraphSAGE є особливо корисною, оскільки такі системи можуть бути дуже великими та динамічними. Вона належить до індуктивних моделей, тобто навчається узагальненій функції агрегації, а не конкретним представленням вузлів. Завдяки цьому модель може

застосовуватися до нових вузлів або змінених конфігурацій мережі без повного перенавчання [14].

Це робить GraphSAGE перспективною для використання в сучасних енергосистемах, зокрема в концепції Smart Grid, де структура мережі може змінюватися. Вона добре підходить для масштабованого аналізу стану мережі та роботи з великими розрідженими графами.

Водночас GraphSAGE також має обмеження: вона не завжди достатньо точно враховує різну важливість зв’язків між вузлами, що є важливим для складних енергетичних систем.

2.3.3 Graph Attention Network (GAT)

Архітектура Graph Attention Network (рисунок 2.8) розширює можливості графових нейронних мереж за рахунок використання механізму уваги. Вона дозволяє вузлу не просто агрегувати інформацію від сусідів, а й визначати, які з них є більш важливими [19].

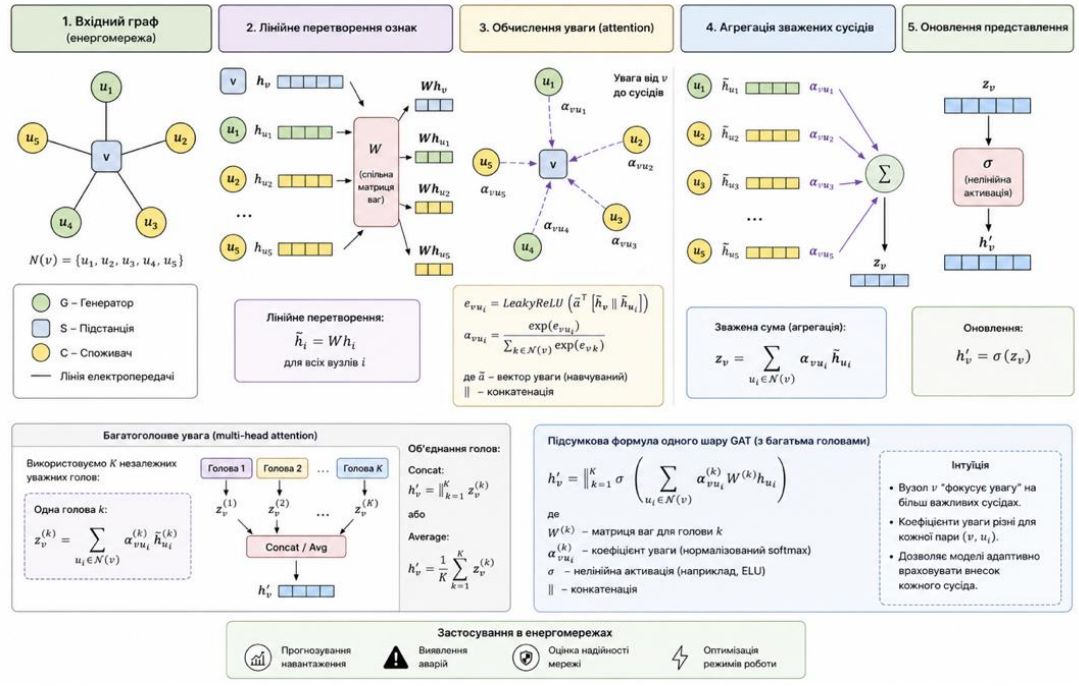


Рисунок 2.8 – Візуалізація GAT

У цій моделі спочатку ознаки вузлів перетворюються, після чого для кожної пари сусідніх вузлів обчислюється коефіцієнт важливості. Ці коефіцієнти нормалізуються і використовуються для зваженого об’єднання інформації від сусідів. Таким чином, кожен вузол отримує більш релевантну інформацію, приділяючи більше уваги ключовим елементам свого оточення.

Для енергетичних систем це має велике значення, оскільки різні елементи мережі можуть мати різний вплив на її стан. Наприклад, магістральні лінії або великі підстанції можуть бути значно важливішими за периферійні елементи. GAT дозволяє автоматично враховувати цю нерівнозначність без ручного налаштування.

Крім того, ця архітектура добре працює з нерегулярними та складними графами, що робить її корисною для задач аналізу та реконфігурації енергомереж після аварій. Вона допомагає визначати критичні вузли та найбільш важливі зв’язки для відновлення системи.

У практиці часто використовується багатоголова увага, коли кілька механізмів уваги працюють паралельно. Це підвищує стабільність навчання та дозволяє враховувати різні аспекти структури графа.

Недоліком GAT є підвищена обчислювальна складність, оскільки для кожного зв’язку необхідно додатково обчислювати коефіцієнти уваги. Проте здатність моделі диференціювати важливість зв’язків часто робить її найбільш ефективною для складних і нерівномірних систем, таких як сучасні енергомережі.

2.4 Порівняння архітектур і обґрунтування вибору

Розглянуті архітектури не є взаємовиключними; радше вони утворюють логічну лінію розвитку графових нейронних мереж від базових до більш адаптивних і точних. GCN є найпростішою і найбільш фундаментальною архітектурою. Вона добре підходить як базова модель

для задач, де граф має відносно стабільну структуру, а головною метою є виявлення загальних топологічних закономірностей. Її перевагами є математична прозорість, простота реалізації та добра інтерпретованість.

GraphSAGE є більш практичним вибором для великих енергетичних мереж, оскільки вона масштабована, підтримує міні-батчеве навчання та здатна працювати індуктивно, тобто узагальнювати знання на нові вузли або змінені конфігурації. Це особливо цінно для сучасних енергосистем, де структура мережі не є абсолютно сталою.

GAT є найбільш гнучкою архітектурою серед трьох розглянутих, оскільки вводить механізм уваги й дозволяє враховувати нерівнозначність зв’язків. Для енергетики це має особливу цінність, адже не всі лінії та вузли однаково впливають на стабільність системи. Саме тому GAT часто розглядається як найперспективніша архітектура для складних задач прогнозування навантаження, виявлення слабких місць та реконфігурації після аварій.

Отже, використання саме GCN, GraphSAGE і GAT у задачах енергетики є обґрунтованим не випадково. Вони репрезентують три ключові підходи до обробки графових даних: базову нормалізовану згортку, масштабовану індуктивну агрегацію та увагове зважування сусідів. У сукупності ці архітектури утворюють методологічну основу для побудови інтелектуальних систем аналізу енергомереж, здатних працювати зі складною, нерегулярною, динамічною та гетерогенною топологією. Саме тому їх розгляд є необхідним етапом перед переходом до математичних основ графових нейронних мереж і подальшої розробки власної моделі для задач прогнозування та реконфігурації енергосистеми.

2.5 Математичні основи графових нейронних мереж

Графові нейронні мережі ґрунтуються на ідеї, що дані зі складною структурою зв’язків не повинні штучно перетворюватися на плоскі таблиці

або ізольовані часові послідовності. Навпаки, їх необхідно аналізувати в тій формі, у якій вони природно існують, тобто як граф. Для енергетичних систем це має особливе значення, оскільки будь-яка електромережа є не просто набором незалежних вузлів, а розгалуженою системою взаємозалежних елементів, у якій генератори, підстанції, трансформатори, розподільчі пункти та споживачі утворюють складну топологічну структуру. У такому середовищі стан одного вузла може впливати на інші, зокрема на віддалені, через послідовність фізичних зв'язків і зміну потоків потужності. Саме тому математичний апарат GNN повинен одночасно враховувати і локальні характеристики вузлів, і структуру взаємодії між ними.

У найзагальнішому вигляді граф енергомережі задається як:

$$G = (V, E), \tag{2.10}$$

де V – множина вузлів;

E – множина ребер.

Якщо модель доповнюється ознаками вузлів, використовується подання:

$$G = (V, E, X), \tag{2.11}$$

де $X \in R^{N \times F}$ – матриця ознак вузлів;

N – кількість вузлів графа;

F – кількість ознак для кожного вузла.

У задачах енергетики вектор ознак вузла може містити активну потужність, реактивну потужність, рівень напруги, тип вузла, технічний стан, координати або інші параметри. У спрощеному вигляді це можна записати як:

$$x_v = [P_v, Q_v, U_v, T_v], \tag{2.12}$$

де P_v – активна потужність;

Q_v – реактивна потужність;

U_v – рівень напруги;

T_v – тип вузла.

У реальній моделі цей набір може бути ширшим і включати часові характеристики, ознаки стабільності або показники споживання.

Ребра графа задають фізичні зв'язки між вузлами й можуть бути подані у вигляді матриці суміжності:

$$A \in R^{N \times N}, \tag{2.13}$$

де елемент a_{ij} – визначає наявність або вагу зв'язку між вузлами i та j .

У найпростішому випадку $a_{ij} \in \{0,1\}$, але для енергетичних систем природнішим є використання зважених графів, де елементи матриці суміжності (рисунок 2.9) можуть містити фізичний зміст: довжину лінії, її пропускну здатність, електричний опір або втрати потужності, тобто граф не є лише абстрактною структурою, а несе інформацію про реальні властивості мережі.

Крім матриці суміжності, фундаментальне значення має матриця ступенів

$$D = diag\,(d_1, d_2, \ldots, d_N), \tag{2.14}$$

$$d_i = \sum_{j=1}^{N} a_{ij}. \tag{2.15}$$

У фізичному сенсі для енергетичної мережі ця матриця відображає інтенсивність локальної зв'язності кожного вузла, тобто те, скільки прямих зв'язків або яка сумарна вага зв'язків припадає на певний елемент системи.

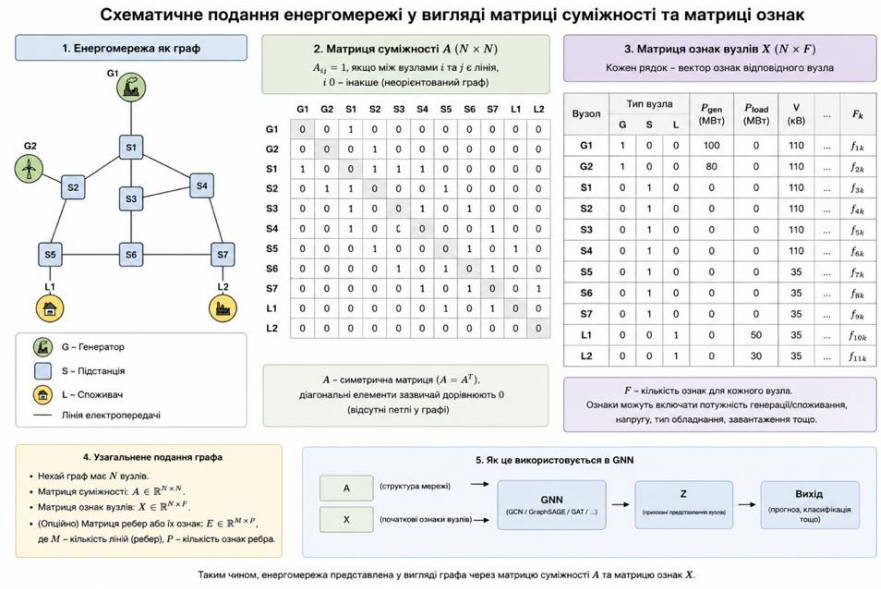


Рисунок 2.9 – Схематичне подання енергомережі у вигляді матриці суміжності та матриці ознак

На основі матриць AAA та DDD визначається графовий лапласіан:

$$L = D - A, \tag{2.16}$$

а в нормалізованому вигляді:

$$L_{norm} = I - D^{-1/2} A D^{-1/2}. \tag{2.17}$$

Лапласіан графа є однією з ключових математичних конструкцій у графовому машинному навчанні. Його можна інтерпретувати як оператор, що показує, наскільки стан вузла відрізняється від станів його сусідів. У випадку енергосистем лапласіан відображає локальні дисбаланси мережі: різницю навантаження між підстанціями, перепади режимів, можливі зони перевантаження або нерівномірності розподілу потужності. Саме тому графовий лапласіан має не лише абстрактне математичне, а й прикладне фізичне значення для дослідження енергомереж.

Однією з базових ідей GNN є те, що інформація в графі повинна поширюватися через локальні зв’язки. Цю ідею найбільш загально формалізує підхід Message Passing Neural Networks (MPNN), який можна розглядати як універсальну модель для багатьох графових архітектур. На кожному шарі вузол отримує повідомлення від своїх сусідів, після чого оновлює власний стан. Формально це описується так:

$$m_v^{(l)} = \sum_{u \in N(v)} M(h_v^{(l)}, h_u^{(l)}, e_{uv}), \tag{2.18}$$

$$h_v^{(l+1)} = U(h_v^{(l)}, m_v^{(l)}), \tag{2.19}$$

де $m_v^{(l)}$ – агреговане повідомлення для вузла v на шарі l;

$M(\cdot)$ – функція передачі повідомлення;

$U(\cdot)$ – функція оновлення;

$h_v^{(l)}$ – представлення вузла;

e_{uv} – ознаки ребра між вузлами u та v.

Зміст цієї формули полягає в тому, що новий стан вузла визначається не лише його власними ознаками, а й сукупністю сигналів, які надходять від локального оточення.

У прикладному сенсі підстанція формує новий стан не ізольовано, а з урахуванням станів суміжних підстанцій, навантажень сусідніх вузлів, параметрів ліній зв’язку та можливих змін у локальному сегменті мережі. Саме тому MPNN є особливо природною моделлю для Smart Grid, де система фактично функціонує як мережа безперервного обміну інформацією й енергією.

На більш спеціалізованому рівні багато GNN-архітектур спираються на операцію графової згортки, яка може бути виведена зі спектральної теорії графів. Якщо в класичних згорткових нейронних мережах згортка

виконується на регулярній сітці зображення, то в графах вона визначається через спектральне розкладання лапласіана:

$$L = U\Lambda U^T, \tag{2.20}$$

де U – матриця власних векторів;

Λ – діагональна матриця власних значень лапласіана.

Для сигналу x, заданого на вершинах графа, графове перетворення Фур'є має вигляд:

$$\hat{x} = U^T x, \tag{2.21}$$

а графова згортка через спектральний фільтр задається як:

$$g_\theta * x = U g_\theta(\Lambda) U^T x. \tag{2.22}$$

В графі, як і в класичних сигналах, можна виділяти «частотні компоненти». Для енергетичної системи низькочастотні компоненти можуть відповідати плавним регіональним змінам навантаження, тоді як високочастотні – локальним стрибкам, аномаліям або аварійним подіям. Хоча пряме спектральне обчислення є дорогим, саме з нього походить теоретична основа графових згорткових мереж.

Для практичного використання було запропоновано спрощення, яке привело до класичної моделі шару GCN.

У цій моделі відбувається нормалізоване згладжування ознак по локальному околу графа: кожен вузол оновлює своє представлення, поєднуючи власні ознаки з інформацією від сусідів, причому внесок кожного сусіда масштабується з урахуванням структури зв'язків у графі. Перед агрегацією ознаки проходять через навчуване перетворення, після чого застосовується нелінійна функція активації.

Для енергомереж така операція відповідає природному фізичному ефекту взаємного впливу вузлів через лінії передачі: сильніше пов’язані вузли мають більший інформаційний обмін, а локальні режими не можуть розглядатися повністю окремо один від одного.

Окремої уваги заслуговує перетворення ознак. На кожному шарі GNN вектори ознак вузлів проходять через навчуване лінійне або нелінійне перетворення. Це дозволяє моделі формувати приховані представлення, які відображають не лише сирі фізичні параметри, а й більш складні структурні закономірності. Якщо початковий вектор вузла містить вимірювані характеристики типу $x_v = [P, Q, U, T]$, то після кількох шарів GNN вузол уже описується ембедінгом, який поєднує локальні ознаки, топологію оточення та інформацію, що надійшла через message passing. Саме ці ембедінги й використовуються далі для прогнозування навантаження, виявлення аномалій або оцінювання критичності вузла.

Водночас математична модель GNN повинна враховувати, що реальні дані енергетичних систем є зашумленими, неповними й часто містять невизначеність. Похибки вимірювання, затримки телеметрії, пропуски в даних, короткочасні флуктуації навантаження або несподівані зміни топології можуть негативно впливати на якість навчання. З цієї причини в практичних реалізаціях часто використовують нормалізацію ознак, регуляризацію, dropout, усереднення по міні-батчах або роботу з робастними функціями втрат. У контексті енергетики це модель повинна бути не лише точною, а й стійкою до природної невизначеності середовища.

Серед фундаментальних обмежень GNN варто згадати явища oversmoothing та oversquashing. У випадку oversmoothing при збільшенні кількості шарів представлення вузлів починають надмірно згладжуватися, і різні вузли стають занадто схожими:

$$h_v^{(l)} \approx h_u^{(l)}, \ \forall u, v. \tag{2.23}$$

Для енергомереж це небезпечно тим, що локальні аномалії або критичні вузли можуть втратити свою індивідуальність у просторі ознак. Інша проблема, oversquashing, пов’язана з тим, що занадто багато віддаленої інформації змушено проходить через вузькі місця графа, через що частина сигналу стискається і втрачається. У реальній енергосистемі це може означати, що важлива інформація з периферійних ділянок недостатньо впливає на центральний вузол моделі, хоча в фізичному сенсі такий вплив може бути суттєвим.

Отже, математичні основи GNN поєднують у собі кілька взаємопов’язаних компонентів: формальне подання графа, матрицю суміжності, матрицю ступенів, лапласіан, механізм message passing, графову згортку, перетворення ознак та засоби врахування невизначеності. У сукупності вони створюють теоретичну основу для побудови моделей, які здатні аналізувати енергомережу як цілісну динамічну систему, а не як набір ізольованих параметрів. Саме це робить GNN природним вибором для задач прогнозування навантаження, виявлення критичних режимів та реконфігурації мережі після збоїв.

2.5 Метрики аналізу графів

Аналіз графової структури енергетичної системи неможливий без використання кількісних метрик, які дозволяють оцінити її внутрішню організацію, ступінь стійкості, критичність окремих вузлів та характер взаємодії між елементами мережі. Такі метрики є важливими не лише для теоретичного опису топології, а й для практичних задач моделювання, оптимізації та машинного навчання. У контексті графових нейронних мереж вони мають подвійне значення: з одного боку, допомагають інтерпретувати початкову структуру мережі, а з іншого – дають змогу краще зрозуміти, чому модель навчається ефективно або, навпаки, стикається з труднощами на певних типах графів.

Для енергосистем метрики графового аналізу є особливо важливими, оскільки топологія безпосередньо впливає на здатність мережі витримувати локальні відмови, уникати каскадних аварій, підтримувати баланс навантаження та забезпечувати резервування маршрутів передачі електроенергії. У межах цієї роботи особливу увагу доцільно приділити трьом групам показників: асортативності, гомофільності та центральності.

2.5.1 Асортативність

Асортативність характеризує тенденцію вузлів мережі з’єднуватися з іншими вузлами, які мають подібні властивості (рисунок 2.10). Найчастіше в аналізі графів використовується асортативність за ступенем, тобто оцінювання того, чи вузли з великою кількістю зв’язків схильні під’єднуватися до інших високозв’язаних вузлів, або ж, навпаки, вони переважно з’єднані з вузлами малого ступеня.

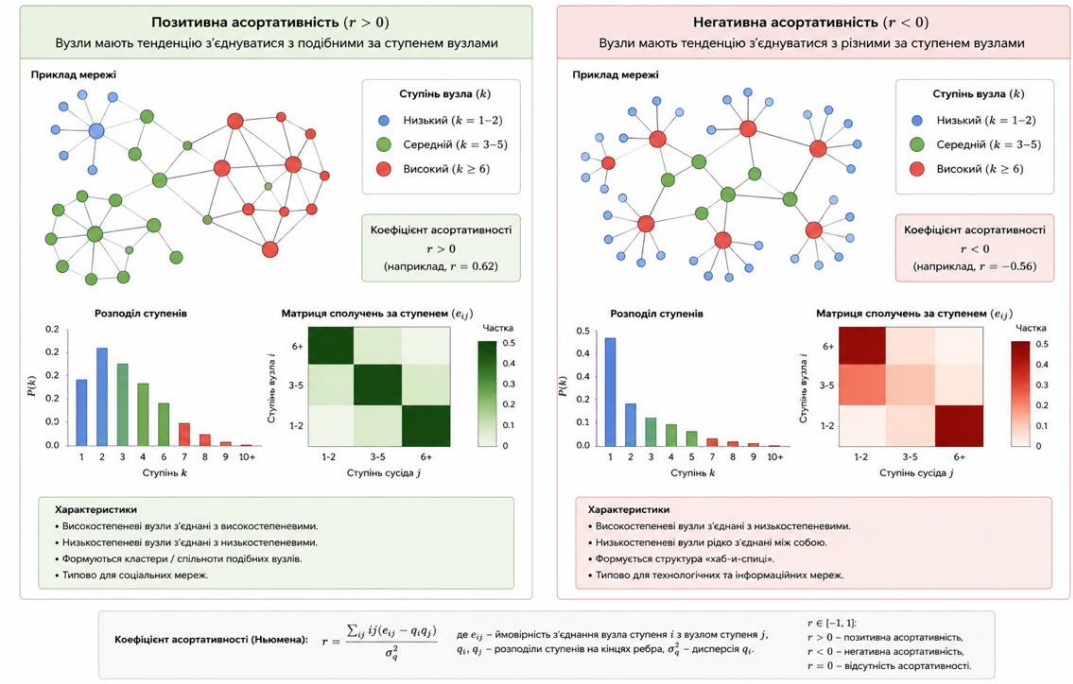


Рисунок 2.10 – Візуалізація мереж із позитивною та негативною асортативністю

Якщо спостерігається позитивна асортативність, подібні за ступенем вузли частіше утворюють зв’язки між собою. Якщо ж мережа є дизасортативною, великі вузли тяжіють до зв’язків із малими.

Коефіцієнт асортативності відображає кореляцію між ступенями з’єднаних вузлів. Його значення зазвичай лежить у діапазоні від −1 до 1: значення, близькі до 1, відповідають високій асортативності, близькі до −1 – дизасортативності, а значення поблизу нуля свідчать про відсутність вираженої залежності.

Для енергетичних систем цей показник має важливий зміст. Якщо вузли великої потужності, наприклад ключові підстанції або магістральні вузли, переважно з’єднані між собою, мережа може краще витримувати локальні коливання та ефективніше перерозподіляти потоки в межах центрального ядра. Водночас надмірна концентрація критичних зв’язків між потужними вузлами може створити ризик масштабних наслідків у разі аварії в такому ядрі. Якщо ж мережа має виражену дизасортативність, це означає, що хаб-вузли підключають велику кількість периферійних елементів. Така структура є типовою для багатьох реальних інфраструктур і може бути ефективною з точки зору передачі, але водночас підвищує вразливість до втрати центральних вузлів.

2.5.2 Гомофільність

Гомофільність описує схильність сусідніх вузлів бути схожими між собою за певними ознаками. На відміну від асортативності, яка зазвичай розглядає кореляцію ступенів або інших глобальніших характеристик, гомофільність фокусується на локальній схожості атрибутів вузлів. У машинному навчанні на графах ця властивість є надзвичайно важливою, оскільки більшість класичних GNN-архітектур ґрунтується на припущенні, що інформація від сусідів є корисною саме тому, що сусідні вузли мають подібні або релевантні властивості.

Коефіцієнт гомофільності відображає частку зв’язків між вузлами з однаковими або подібними характеристиками. Чим вище його значення, тим сильніше виражена локальна однорідність графа.

У контексті енергетики гомофільність може проявлятися, наприклад, у тому, що підстанції одного класу напруги, вузли зі схожим профілем навантаження або групи споживачів одного типу частіше взаємодіють між собою через спільну інфраструктуру. Висока гомофільність сприяє ефективності стандартних GNN, оскільки сусідні вузли дійсно містять релевантну інформацію один про одного. Якщо ж мережа є гетерофільною, тобто сусідні вузли мають сильно відмінні характеристики, класичні GNN можуть працювати гірше, оскільки просте усереднення ознак призводить до розмиття інформації. Це особливо характерно для графів, де генератори, трансформатори та споживачі безпосередньо взаємодіють, маючи при цьому дуже різні функції та параметри.

Для задач цієї кваліфікаційної роботи гомофільність є важливою ще й тому, що вона впливає на вибір архітектури графової нейронної мережі. Якщо структура мережі є відносно гомофільною, базові підходи можуть бути достатньо ефективними. Якщо ж енергомережа виражено гетерогенна, більш доцільним може бути використання архітектур із механізмом уваги.

2.5.3 Центральність

Центральність – це група метрик, які визначають важливість або впливовість вузла в структурі графа (рисунок 2.11). Для енергетичних систем такі метрики мають особливе практичне значення, оскільки дозволяють виявити критичні точки мережі, від яких залежить передача потужності, зв’язність системи та стійкість до відмов.

Найпростішою є степенева центральність, яка визначається кількістю зв’язків вузла. У енергомережі високе значенням цієї метрики є

безпосередньо пов’язаний вузол із великою кількістю інших вузлів, наприклад є важливим розподільчим пунктом.

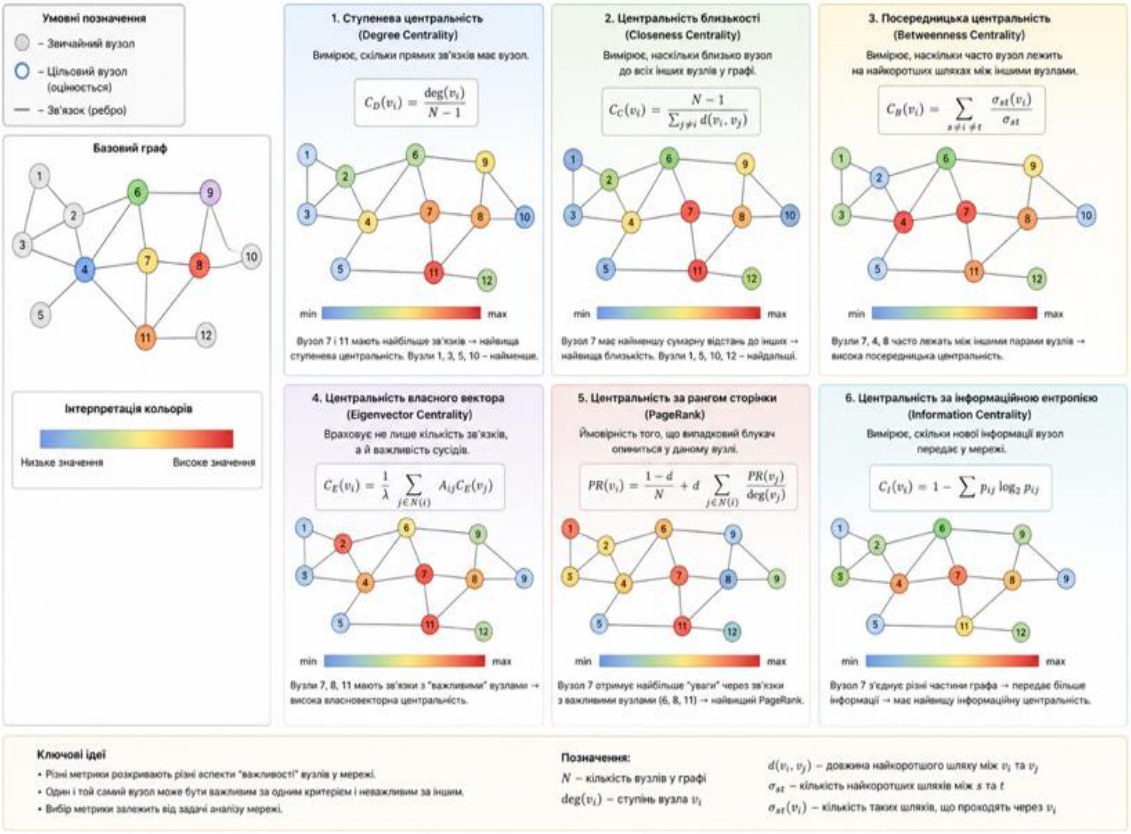


Рисунок 2.11 – Візуалізація вузлів із різними типами центральності

Більш інформативною є міжцентральність, яка показує, як часто вузол лежить на найкоротших шляхах між іншими вузлами. Тобто, наскільки часто вузол виконує роль транзитної точки. Навіть якщо вузол не має великої кількості прямих зв’язків, він може бути критично важливим для передачі енергії між різними частинами мережі.

Центральність за близькістю оцінює, наскільки «близько« вузол розташований до інших у мережі з точки зору довжин шляхів. Високе значення означає, що вузол може швидко взаємодіяти з більшістю інших елементів системи, що є важливим для аналізу поширення збурень або управління мережею.

Також варто згадати центральність за власним вектором, яка враховує не лише кількість зв’язків вузла, а й важливість його сусідів. Це дозволяє виявляти вузли, що належать до центрального «ядра» мережі.

У контексті цієї роботи метрики центральності мають практичне значення: вони можуть використовуватися як додаткові ознаки для моделей, допомагати виявляти критичні вузли та інтерпретувати результати прогнозування.

3 РОЗРОБКА МОДЕЛІ ПРОГНОЗУВАННЯ ТА РЕКОНФІГУРАЦІЇ ЕНЕРГОМЕРЕЖІ

3.1 Формалізація задачі у вигляді графа

Сучасні енергетичні системи характеризуються складною структурою взаємозв’язків між елементами генерації, передачі та споживання електроенергії. У таких системах стан кожного вузла залежить не лише від його локальних параметрів, а й від топологічного положення в мережі, параметрів сусідніх елементів та поточних режимів роботи системи. Саме тому для задач прогнозування навантаження та реконфігурації енергомереж доцільним є використання графового подання, яке дозволяє відобразити структуру мережі та взаємозалежність між її компонентами.

У ролі вузлів графа виступають bus-системи енергомережі, які можуть представляти електростанції, трансформаторні підстанції або центри споживання електроенергії. Ребра графа відповідають фізичним лініям електропередач, через які здійснюється передача потужності між вузлами системи.

Для проведення дослідження використовується тестова енергомережа IEEE 14-bus, що є однією з найбільш поширених моделей у задачах аналізу енергетичних систем. Використання саме цієї топології пояснюється тим, що вона містить достатню кількість вузлів і зв’язків для моделювання процесів прогнозування, аварійних ситуацій та реконфігурації мережі, водночас залишаючись придатною для візуального аналізу та експериментальних досліджень.

Кожен вузол графа характеризується набором параметрів, які формують його вектор ознак:

$$x_v = [P, Q, U, Type], \tag{3.2}$$

де P – активне навантаження вузла;

Q – реактивна потужність;

U – рівень напруги;

$Type$ – тип вузла.

У межах роботи використовуються генераторні вузли, вузли-підстанції та вузли споживання. Таке подання дозволяє моделі враховувати як електричні характеристики вузла, так і його функціональну роль у структурі енергомережі. Це особливо важливо для графових нейронних мереж, оскільки різні типи вузлів мають різний вплив на поведінку системи. Наприклад, генераторні вузли є джерелами потужності та забезпечують живлення інших елементів мережі, тоді як вузли споживання формують навантаження системи.

У межах графової моделі структура мережі визначається матрицею суміжності, яка описує наявність або відсутність зв’язків між вузлами. Це дозволяє графовій нейронній мережі виконувати агрегацію інформації між сусідніми елементами системи та враховувати топологічні залежності у процесі прогнозування.

На відміну від класичних моделей часових рядів, графове подання забезпечує одночасне врахування часової динаміки та просторової структури мережі. Такий підхід є особливо важливим для енергетичних систем, оскільки зміни навантаження або аварійні ситуації в одному вузлі можуть безпосередньо впливати на роботу сусідніх елементів.

Окремою перевагою графового подання є можливість моделювання аварійних сценаріїв шляхом зміни структури графа. Видалення вузлів або ребер дозволяє імітувати пошкодження елементів енергомережі, аналізувати втрату зв’язності та досліджувати процес відновлення системи після аварії. Таким чином, графова модель створює основу не лише для прогнозування навантаження, а й для реалізації алгоритмів реконфігурації енергомережі.

3.2 Побудова графа на основі даних енергомережі

Після формалізації енергомережі у вигляді графа наступним етапом є створення її програмної моделі та підготовка даних для навчання графових нейронних мереж. У межах роботи побудова графа здійснювалася у середовищі Python із використанням бібліотеки NetworkX, яка дозволяє ефективно працювати з графовими структурами та виконувати аналіз топології мережі.

Основою графа стала тестова система IEEE 14-bus, яка містить 14 вузлів та 20 ліній електропередач. Кожен вузол був представлений окремою вершиною графа, а кожна лінія електропередач – ребром між відповідними вершинами. У результаті було сформовано неорієнтований граф, що відображає структуру енергомережі та взаємозв’язки між її елементами.

У процесі побудови графа для кожного вузла задавався набір характеристик, необхідних для подальшого прогнозування навантаження. До основних параметрів належать активна потужність, реактивне навантаження, рівень напруги та тип вузла. Таке представлення дозволяє графовій нейронній мережі враховувати фізичний стан енергосистеми під час навчання.

Оскільки тестова система IEEE 14-bus не містить великого набору часових даних навантаження, у роботі було використано синтетичну генерацію часових рядів. Це дозволило сформувати динамічні зміни навантаження вузлів та змоделювати реальні умови функціонування енергосистеми.

Такий підхід дозволяє моделювати характерні добові коливання споживання електроенергії, а також випадкові зміни навантаження, які виникають у реальних енергетичних системах. Використання шумової компоненти є особливо важливим, оскільки сучасні енергомережі працюють в умовах постійної невизначеності, що пов’язана зі зміною

поведінки споживачів, погодними умовами та нестабільністю відновлюваних джерел енергії.

Отримані часові ряди використовувалися для формування послідовності станів мережі. Для кожного моменту часу створювався окремий графовий об’єкт, який містив поточні значення ознак вузлів та структуру зв’язків між ними. Цільовим значенням для моделі було навантаження вузлів на наступний часовий момент, що дозволило реалізувати задачу прогнозування часових змін у мережі.

Для подальшої роботи графові дані були перетворені у формат бібліотеки PyTorch Geometric. У такому форматі кожен стан мережі містить матрицю ознак вузлів, список ребер графа та набір цільових значень для навчання. Це забезпечує можливість ефективного використання графових нейронних мереж та виконання операцій агрегації інформації між вузлами.

Важливою особливістю побудованої моделі є можливість динамічної зміни топології мережі. У процесі експериментів окремі лінії електропередач можуть видалятися або додаватися, що дозволяє моделювати аварійні ситуації та реконфігурацію енергосистеми. Таким чином, створений граф є не статичною структурою, а адаптивною моделлю енергомережі, придатною для аналізу стійкості та поведінки системи при зміні її конфігурації.

3.3 Алгоритм реконфігурації при збої

Однією з ключових задач сучасних енергетичних систем є забезпечення безперервності електропостачання навіть у випадку пошкодження окремих елементів мережі. Вихід з ладу ліній електропередач або вузлів може призводити до порушення зв’язності системи, ізоляції окремих компонентів та втрати живлення споживачів. У зв’язку з цим важливою складовою даної роботи є реалізація алгоритму реконфігурації

енергомережі, здатного автоматично відновлювати структуру графа після виникнення аварійної ситуації.

У межах роботи реконфігурація розглядається як процес зміни топології графа після пошкодження частини його ребер. Аварійна ситуація моделюється шляхом видалення ліній електропередач із графа, що відповідає фізичному відключенню елементів енергосистеми. На відміну від попереднього базового сценарію, де видалення одного вузла не призводило до втрати зв’язності мережі, у фінальному експерименті було реалізовано сценарій множинної відмови ліній.

Для моделювання аварії було відключено дві лінії електропередач: (9,14),(13,14)(9,14), (13,14)(9,14),(13,14).

У результаті вузол 14 втрачає всі основні зв’язки з мережею та стає ізольованим. Це призводить до розділення графа на дві окремі компоненти зв’язності.

Після виникнення аварії було виконано аналіз компонент зв’язності графа. Результати показали, що енергомережа розділилася на дві незалежні частини: основну компоненту, яка містить вузли від 1 до 13, та ізольований вузол 14.

У реальних енергосистемах подібні ситуації можуть призводити до локальних відключень споживачів або перевантаження інших ділянок мережі. Саме тому наступним етапом є виконання реконфігурації системи.

У межах роботи реконфігурація здійснюється шляхом активації резервних ліній електропередач. Для цього формується набір потенційних резервних ребер, які можуть бути додані до графа у випадку втрати зв’язності. Алгоритм послідовно перевіряє можливість додавання резервних зв’язків та оцінює, чи забезпечує це об’єднання всіх компонент мережі в єдиний граф.

У процесі експерименту було встановлено, що додавання резервного ребра між вузлами 14 та 10 дозволяє повністю відновити зв’язність системи.

Після активації резервної лінії мережа знову переходить у стан єдиної компоненти зв’язності, що свідчить про успішне відновлення працездатності енергосистеми.

Для оцінки ефективності реконфігурації використовувалася метрика коефіцієнта відновлення навантаження:

$$R = \frac{P_{restored}}{P_{total}}, \tag{3.3}$$

де $P_{restored}$ – навантаження вузлів, що залишилися підключеними після реконфігурації;

P_{total} – сумарне навантаження мережі до аварії.

Отримані результати показали, що після пошкодження частина навантаження була втрачена через ізоляцію вузла 14, однак після реконфігурації значення коефіцієнта відновлення досягло. Це є повним відновлення працездатності мережі та повернення всіх вузлів до єдиної структури графа.

Додатково було виконано аналіз центральності вузлів до аварії, після пошкодження та після реконфігурації (рисунок 3.1). Встановлено, що після ізоляції вузла 14 його центральність зменшується до нульового значення, оскільки він повністю втрачає зв’язок із мережею.

Аналіз центральності вузлів:

	Node	Degree Centrality Before	After Failure	After Reconfiguration
0	1	0.153846	0.153846	0.153846
1	2	0.307692	0.307692	0.307692
2	3	0.153846	0.153846	0.153846
3	4	0.384615	0.384615	0.384615
4	5	0.307692	0.307692	0.307692
5	6	0.307692	0.307692	0.307692
6	7	0.230769	0.230769	0.230769
7	8	0.076923	0.076923	0.076923
8	9	0.307692	0.230769	0.230769
9	10	0.153846	0.153846	0.230769
10	11	0.153846	0.153846	0.153846
11	12	0.153846	0.153846	0.153846
12	13	0.230769	0.153846	0.153846
13	14	0.153846	0.000000	0.076923

Рисунок 3.1 – Аналіз центральності вузлів

Після активації резервного ребра значення центральності знову зростає, що підтверджує відновлення ролі вузла у структурі енергосистеми.

Також було проведено аналіз загальних характеристик графа (рисунок 3.2). Після аварії мережа переходить у disconnected state, через що середня довжина найкоротшого шляху перестає бути визначеною. Після реконфігурації всі основні характеристики графа повертаються до значень, близьких до початкових.

Загальні метрики графа:

	Scenario	Nodes	Edges	Connected Components	Average Degree	Average Clustering	Average Shortest Path
0	Before Failure	14	20	1	2.857143	0.366667	2.373626
1	After Failure	14	18	2	2.571429	0.426190	NaN
2	After Reconfiguration	14	19	1	2.714286	0.426190	2.560440

Рисунок 3.2 – Загальні метрики графа

Таким чином, реалізований алгоритм реконфігурації продемонстрував здатність автоматично відновлювати структуру енергомережі після пошкодження ліній електропередач. Використання графового подання дозволило ефективно аналізувати зміну топології мережі, визначати втрату зв’язності та знаходити оптимальні резервні зв’язки для відновлення системи.

3.4 Архітектура GNN-моделі

Для реалізації задачі прогнозування навантаження у роботі було використано графові нейронні мережі, які дозволяють враховувати не лише часову динаміку даних, але й топологічну структуру енергомережі. На відміну від класичних нейронних мереж, GNN виконують обробку інформації безпосередньо на графах, що робить їх особливо придатними для задач аналізу енергетичних систем.

Основний принцип роботи графових нейронних мереж полягає у передачі інформації між сусідніми вузлами графа. Кожен вузол отримує ознаки від своїх сусідів, агрегує їх та формує нове представлення власного стану. У загальному вигляді процес оновлення ознак вузлів описується як:

$$h_v^{(l+1)} = U(h_v^{(l)}, m_v^{(l)}), \tag{3.4}$$

де $h_v^{(l)}$ – представлення вузла на поточному шарі;

$m_v^{(l)}$ – агрегована інформація від сусідніх вузлів.

У межах роботи було реалізовано три архітектури графових нейронних мереж: GCN, GraphSAGE та GAT. Їх використання дозволяє порівняти різні механізми агрегації інформації у графі та оцінити ефективність кожного підходу для задач прогнозування навантаження.

GCN є базовою архітектурою графових нейронних мереж та використовує механізм графової згортки для передачі інформації між сусідніми вузлами. Модель виконує нормалізовану агрегацію ознак, що дозволяє враховувати локальні топологічні залежності між елементами мережі. Перевагою GCN є відносна простота реалізації та стабільність навчання.

GraphSAGE використовує індуктивний підхід до агрегації сусідів і виконує вибірковий семплінг локального оточення вузла. Такий механізм дозволяє ефективно працювати з великими графами та забезпечує кращу здатність до узагальнення. У контексті енергетичних систем це особливо важливо, оскільки реальні Smart Grid мережі можуть містити тисячі вузлів і динамічно змінювати свою структуру.

Третьою архітектурою є GAT – Graph Attention Network, яка використовує attention-механізм для визначення важливості сусідніх вузлів. На відміну від GCN і GraphSAGE, де всі сусіди впливають на вузол

приблизно однаково, GAT дозволяє автоматично визначати, які зв’язки є більш значущими для прогнозування.

Для енергетичних систем це має особливе значення, оскільки різні лінії електропередач мають неоднаковий вплив на роботу мережі. Наприклад, магістральна високовольтна лінія є значно важливішою для стабільності системи, ніж локальна розподільча ділянка. Attention-механізм дозволяє моделі автоматично враховувати подібні відмінності у структурі графа.

У межах програмної реалізації всі моделі були побудовані із використанням двох графових шарів та вихідного повнозв’язного шару для прогнозування навантаження вузлів. Для GAT додатково використовувалися multi-head attention та dropout-регуляризація, що дозволило підвищити стабільність навчання та зменшити ризик перенавчання.

Таким чином, використані архітектури забезпечують різні підходи до обробки графових структур та дозволяють дослідити вплив механізмів агрегації на точність прогнозування навантаження енергомережі.

3.5 Вибір функції втрат і оптимізатора

Одним із важливих етапів побудови графової нейронної мережі є вибір функції втрат та алгоритму оптимізації, які визначають процес навчання моделі та якість отриманих результатів.

Оскільки у межах роботи розв’язується задача прогнозування числових значень навантаження, основною функцією втрат було обрано середньоквадратичну помилку (Mean Squared Error, MSE):

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y_i})^2, \tag{3.5}$$

де y_i – реальне значення навантаження;

$\widehat{y_i}$ – прогноз моделі.

Використання MSE пояснюється її високою чутливістю до великих помилок прогнозування. Для енергетичних систем це є важливим, оскільки значні відхилення прогнозу можуть призводити до перевантаження окремих елементів мережі або помилкової оцінки її стійкості.

Для додаткової оцінки точності прогнозування використовувалася метрика SMAPE, яка є більш стабільною при роботі з малими значеннями навантаження:

$$SMAPE = \frac{1}{n}\sum_{i=1}^{n}\frac{2|y_i-\widehat{y_i}|}{|y_i|+|\widehat{y_i}|}\cdot 100\%. \quad (3.6)$$

Використання SMAPE дозволило уникнути проблем, характерних для класичної MAPE, де помилка може різко зростати при значеннях навантаження, близьких до нуля.

У ролі оптимізатора було використано алгоритм Adam, який забезпечує адаптивне оновлення параметрів моделі та демонструє високу стабільність при навчанні глибоких нейронних мереж. У процесі експериментів швидкість навчання становила 0.005, а кількість епох навчання – 120.

Для моделі GAT додатково використовувалася dropout-регуляризація, що дозволило зменшити ризик перенавчання attention-механізму та забезпечити більш стабільну збіжність функції втрат.

Таким чином, обрані функція втрат та оптимізатор забезпечили коректне навчання моделей та дозволили отримати стабільні результати прогнозування навантаження енергомережі.

3.6 Навчання моделі та оцінка точності

Навчання графових нейронних мереж виконувалося на основі синтетичних часових рядів навантаження, сформованих для вузлів тестової

системи IEEE 14-bus. Для кожного моменту часу створювався окремий графовий стан мережі, який містив поточні ознаки вузлів та структуру зв’язків між ними.

У процесі підготовки даних 80% графових об’єктів використовувалися для навчання моделей, тоді як решта 20% – для тестування. Такий підхід дозволяє оцінити здатність моделей узагальнювати інформацію та прогнозувати навантаження для нових станів системи.

У ході навчання для кожної моделі обчислювалося значення функції втрат MSE. Отримані результати демонструють поступове зменшення помилки прогнозування та збіжність моделей у процесі навчання.

Аналіз графіка функції втрат показує, що всі моделі демонструють стабільне навчання, однак характер збіжності для них відрізняється. GraphSAGE забезпечує найшвидшу стабілізацію функції втрат та демонструє найменший рівень помилки прогнозування. GCN також показує стабільну поведінку, однак поступається GraphSAGE за точністю. У випадку GAT спостерігаються більш помітні коливання loss-функції, що пояснюється складністю attention-механізму та більшою кількістю параметрів моделі.

Отримані результати показали, що найкращу точність прогнозування продемонструвала модель GraphSAGE. Це пояснюється використанням neighbor sampling та індуктивного механізму агрегації, які забезпечують кращу здатність моделі до узагальнення навіть на відносно невеликих графах.

Модель GCN продемонструвала задовільну точність та стабільне навчання, однак виявилася менш ефективною через обмежену здатність враховувати складні локальні залежності між вузлами мережі.

Незважаючи на нижчу точність у межах даного експерименту, GAT залишається перспективною архітектурою для задач енергетики. Використання attention-механізму дозволяє моделі визначати важливість

окремих зв’язків між вузлами, що є особливо важливим для складних Smart Grid систем із неоднорідною структурою.

Додатково було проведено порівняння прогнозованих та реальних значень навантаження.

Результати демонструють, що графові нейронні мережі здатні ефективно відтворювати основні закономірності зміни навантаження та коректно прогнозувати динаміку часових рядів навіть за наявності шуму та випадкових коливань у даних.

Також було виконано порівняння графових моделей із класичним методом часових рядів ARIMA. На відміну від ARIMA, графові нейронні мережі враховують не лише часову динаміку, але й топологічні взаємозв’язки між вузлами мережі. Це забезпечує більш адаптивне прогнозування та дозволяє моделі реагувати на зміну структури енергосистеми.

Проведені експерименти підтвердили ефективність використання графових нейронних мереж у задачах прогнозування навантаження та аналізу стійкості енергомережі.

4 ПРАКТИЧНА РЕАЛІЗАЦІЯ, РЕЗУЛЬТАТИ ТА ПОРІВНЯННЯ МЕТОДІВ

4.1 Використані технології, середовище та підготовка даних

Практична реалізація системи прогнозування та реконфігурації енергомережі виконувалася у середовищі Python із використанням сучасних бібліотек для обробки графових структур, машинного навчання та візуалізації даних. Вибір саме Python пояснюється широким набором інструментів для роботи з графовими нейронними мережами, підтримкою наукових обчислень та високою гнучкістю при створенні дослідницьких моделей.

Розробка та запуск моделі здійснювалися у середовищі Google Colab. Використання хмарного середовища дозволило уникнути обмежень локального обладнання, спростити процес тестування моделі та забезпечити підтримку GPU-прискорення для навчання графових нейронних мереж. Окрім цього, Google Colab забезпечує зручну інтеграцію з Python-бібліотеками та дозволяє виконувати повний цикл експерименту – від генерації даних до візуалізації результатів – в одному середовищі.

Для побудови та аналізу графової структури енергомережі використовувалася бібліотека NetworkX. Вона забезпечила створення топології IEEE 14-bus, виконання операцій із вузлами та ребрами, аналіз зв’язності мережі, обчислення метрик центральності та моделювання аварійних ситуацій. Використання NetworkX також дозволило реалізувати візуалізацію графа у різних режимах роботи системи, включаючи нормальний стан мережі, аварійний режим та реконфігурацію після відновлення зв’язності.

Для реалізації графових нейронних мереж використовувалася бібліотека PyTorch Geometric, яка є спеціалізованим розширенням PyTorch для роботи з графовими структурами. Саме PyTorch Geometric забезпечує

реалізацію GCN, GraphSAGE та GAT, а також підтримує механізми message passing, neighbor aggregation та attention. Завдяки цій бібліотеці стало можливим ефективне навчання моделей без необхідності самостійної реалізації складних алгоритмів агрегації інформації у графі.

Обробка числових даних та генерація часових рядів виконувалися із використанням бібліотек NumPy та Pandas. NumPy використовувався для математичних операцій та генерації синтетичних навантажень вузлів, тоді як Pandas забезпечував зручну роботу з таблицями даних та формуванням структурованих наборів для подальшого навчання моделей.

Візуалізація результатів виконувалася за допомогою бібліотеки Matplotlib. Це дозволило побудувати графіки функції втрат, часових рядів навантаження, порівняння реальних та прогнозованих значень, а також графічне представлення топології енергомережі в різних режимах роботи.

Основою практичної реалізації стала тестова система IEEE 14-bus (рисунок 4.1). Вона містить 14 вузлів та 20 ліній електропередач і широко використовується у дослідженнях енергетичних систем. Така топологія забезпечує достатню складність для аналізу процесів прогнозування та реконфігурації, водночас залишаючись придатною для візуального аналізу та експериментальної перевірки роботи графових алгоритмів.

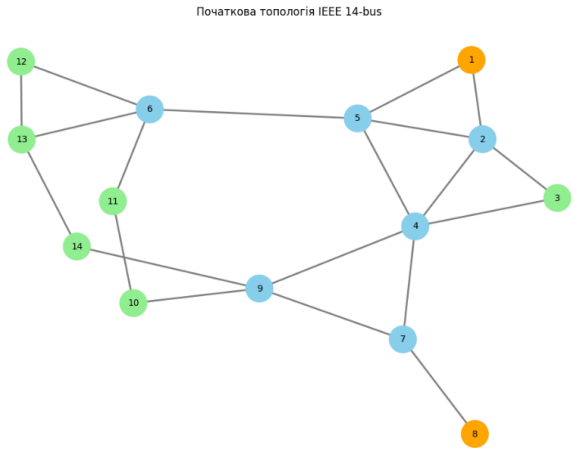


Рисунок 4.1 – Початкова топологія IEEE 14-bus

Оскільки реальні часові ряди навантаження (рисунок 4.2) для IEEE 14-bus у межах даного дослідження не використовувалися, було реалізовано механізм синтетичної генерації навантаження. Для кожного вузла формувався часовий ряд, що поєднував базове навантаження, періодичні коливання та випадковий шум. Такий підхід дозволив змоделювати поведінку реальної енергомережі в умовах нестабільності та невизначеності.

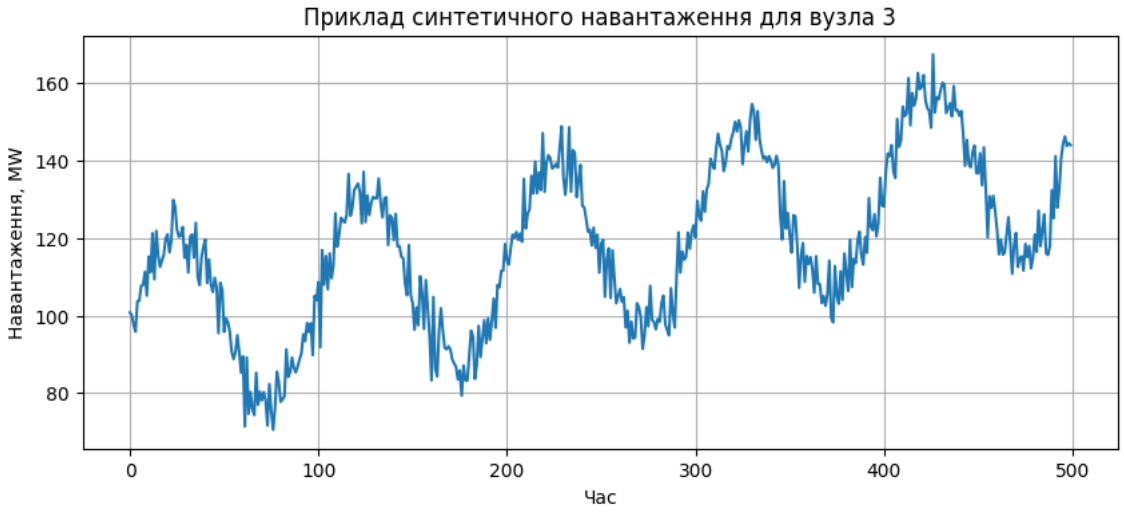


Рисунок 4.2 – Приклад синтетичного навантаження для вузла 3

У процесі генерації даних враховувалися добові коливання навантаження та випадкові відхилення, що моделюють вплив нестабільності споживання, погодних умов та змін режимів роботи системи. Це дозволило сформувати набір даних, достатній для навчання графових нейронних мереж та подальшого аналізу їхньої здатності прогнозувати навантаження.

Для кожного моменту часу створювався окремий графовий стан мережі, який містив структуру зв’язків між вузлами та поточні значення їхніх ознак. У результаті було сформовано набір графових об’єктів, які використовувалися як вхідні дані для моделей GCN, GraphSAGE та GAT.

Під час підготовки даних навчальна та тестова вибірки формувалися у співвідношенні 80% до 20%. Навчальна частина використовувалася для оптимізації параметрів моделей, тоді як тестова – для оцінки точності прогнозування та порівняння різних архітектур графових нейронних мереж.

Окрему увагу було приділено моделюванню аварійних ситуацій. Для цього у графі виконувалося відключення окремих ліній електропередач, що призводило до зміни структури мережі та втрати зв’язності між окремими вузлами. У фінальному сценарії було відключено лінії між вузлами 9–14 та 13–14, у результаті чого вузол 14 став ізольованим від основної компоненти графа (рисунок 4.3).

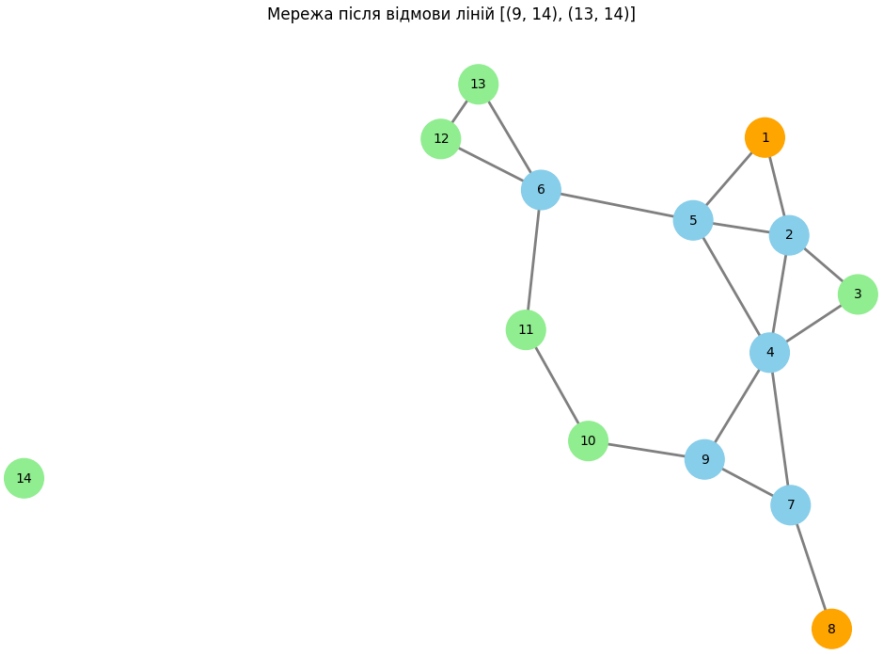


Рисунок 4.3 – Мережа після аварійного відключення ліній

Після виникнення аварії мережа розділилася на дві окремі компоненти зв’язності. Основна компонента містила вузли від 1 до 13, тоді як вузол 14 опинився повністю ізольованим. Отримані результати підтвердили коректність реалізованого механізму моделювання аварійних ситуацій та дозволили перейти до дослідження реконфігурації мережі.

Для відновлення зв’язності використовувалися резервні лінії електропередач. У процесі експерименту було встановлено, що додавання резервного ребра між вузлами 14 та 10 дозволяє повністю відновити структуру мережі (рисунок 4.4).

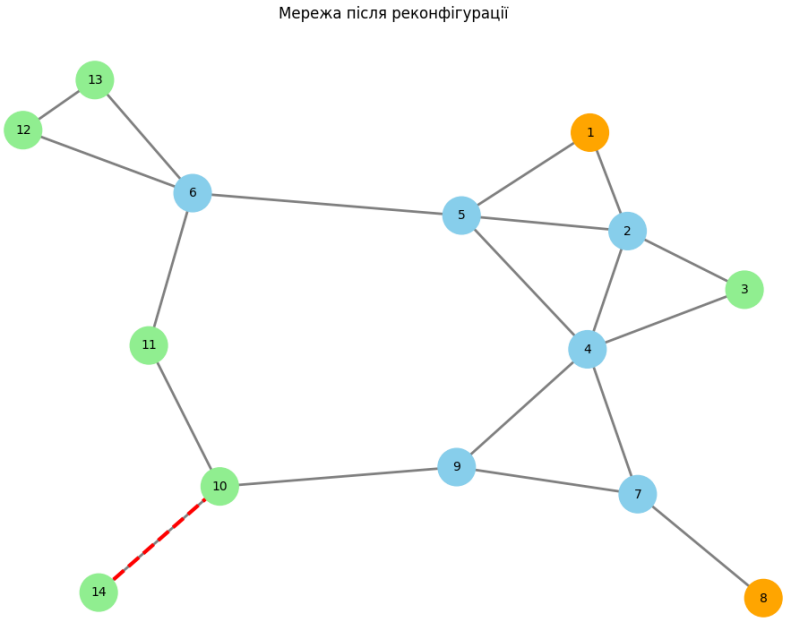


Рисунок 4.4 – Мережа після реконфігурації

Після реконфігурації мережа знову перейшла у стан єдиної компоненти зв’язності, а коефіцієнт відновлення навантаження досяг значення 1.0, що свідчить про повне відновлення працездатності системи.

Таким чином, створене програмне середовище забезпечило повний цикл дослідження: побудову графа енергомережі, генерацію часових рядів навантаження, навчання графових нейронних мереж, моделювання аварійних ситуацій та реконфігурацію системи після пошкоджень.

4.2 Архітектура програмного рішення

Архітектура програмного рішення була побудована таким чином, щоб забезпечити повний цикл роботи системи прогнозування та реконфігурації

енергомережі – від формування графа та генерації даних до аналізу аварійних ситуацій і оцінки стійкості мережі. У межах роботи система реалізована як модульна структура, де окремі компоненти відповідають за побудову графа, підготовку даних, навчання графових нейронних мереж, моделювання аварій та реконфігурацію топології.

Першим етапом роботи системи є побудова графової структури енергомережі. На цьому етапі створюється топологія IEEE 14-bus, формуються вузли та ребра графа, а також задаються параметри елементів мережі. Кожен вузол містить інформацію про навантаження, тип елемента та інші характеристики, необхідні для роботи графових нейронних мереж.

Після створення структури графа система переходить до генерації часових даних. Для кожного вузла формується синтетичний часовий ряд навантаження, який імітує зміну споживання електроенергії у часі. Дані включають періодичні коливання та випадковий шум, що дозволяє моделювати нестабільність реальних енергетичних систем.

На наступному етапі формується набір графових об’єктів для навчання моделей. Кожен стан мережі перетворюється у формат PyTorch Geometric та містить структуру зв’язків між вузлами, матрицю ознак і цільові значення для прогнозування навантаження. Після цього система виконує розподіл даних на навчальну та тестову вибірки.

Центральною частиною програмного рішення є модуль графових нейронних мереж. У межах системи реалізовано три окремі архітектури: GCN, GraphSAGE та GAT. Кожна модель містить два графові шари та вихідний повнозв’язний шар для прогнозування навантаження вузлів. Під час навчання система автоматично обчислює функцію втрат, виконує оптимізацію параметрів та зберігає результати прогнозування.

Окремий модуль відповідає за моделювання аварійних ситуацій. У процесі роботи система може видаляти окремі ребра графа, що відповідає пошкодженню ліній електропередач. Після цього виконується аналіз

компонент зв’язності, визначаються ізольовані вузли та оцінюється вплив аварії на структуру мережі.

У фінальному експерименті система виконувала відключення ліній між вузлами 9–14 та 13–14, у результаті чого вузол 14 був ізольований від основної компоненти графа. Після цього модуль реконфігурації виконував пошук резервних зв’язків для відновлення працездатності системи.

Після аналізу доступних резервних ліній система визначила, що додавання ребра між вузлами 14 та 10 дозволяє повністю відновити зв’язність мережі. Після реконфігурації виконувалося повторне обчислення метрик графа та аналіз зміни центральності вузлів.

Окремий модуль системи відповідає за візуалізацію результатів. Він забезпечує побудову графіків функції втрат, порівняння прогнозованих і реальних значень навантаження, а також графічне представлення структури мережі до аварії, після пошкодження та після реконфігурації (рисунок 4.5).

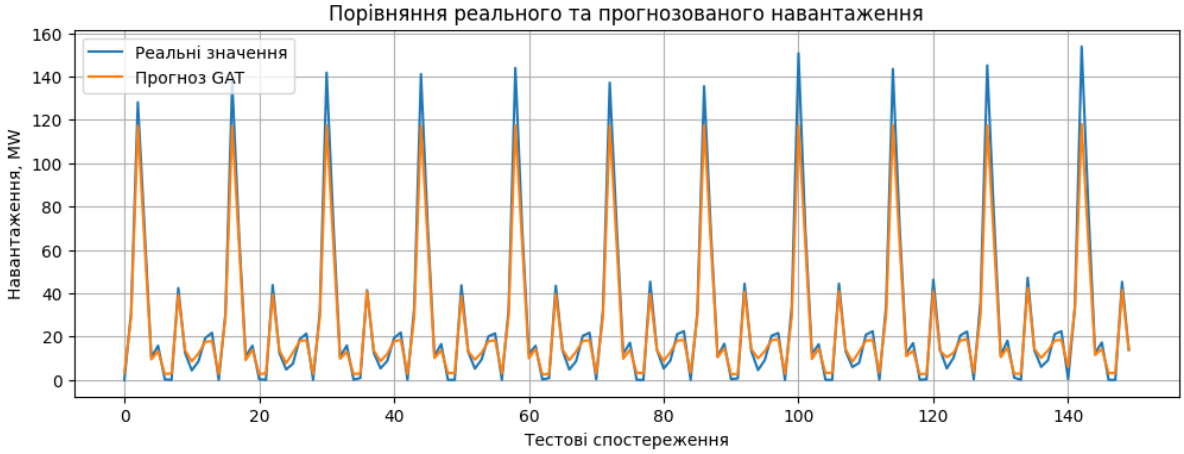


Рисунок 4.5 – Порівняння реального та прогнозованого навантаження

Таким чином, архітектура програмного рішення забезпечує повний цикл роботи інтелектуальної системи прогнозування та реконфігурації енергомережі. Побудована система поєднує графові нейронні мережі, аналіз структури графа та моделювання аварійних ситуацій, що дозволяє

досліджувати поведінку енергосистеми в умовах невизначеності та зміни топології мережі.

4.3 Отримані результати моделі (графи, прогноз, реконфігурація)

Після завершення навчання графових нейронних мереж було проведено серію експериментів для оцінки якості прогнозування навантаження, аналізу поведінки моделі при аварійних ситуаціях та перевірки ефективності реконфігурації енергомережі. Основною метою експериментів стало визначення здатності графових моделей враховувати топологію мережі та забезпечувати стабільну роботу системи в умовах зміни структури графа.

У процесі дослідження було протестовано три архітектури графових нейронних мереж: GCN, GraphSAGE та GAT. Навчання моделей виконувалося на синтетичних часових рядах навантаження, сформованих для вузлів IEEE 14-bus. Для оцінки точності використовувалися метрики MAE, RMSE та SMAPE.

Отримані результати показали, що найкращу якість прогнозування продемонструвала модель GraphSAGE. Вона забезпечила найменше значення RMSE та найбільш стабільне навчання серед усіх протестованих архітектур. Це пояснюється використанням механізму neighbor sampling, який дозволяє ефективно агрегувати інформацію від сусідніх вузлів та краще узагальнювати дані навіть на відносно невеликих графах.

Модель GCN також продемонструвала стабільні результати прогнозування та коректну збіжність функції втрат, однак поступилася GraphSAGE за точністю. Причиною цього є більш простий механізм агрегації сусідів, який менш ефективно враховує складні локальні залежності у структурі енергомережі.

Модель GAT показала нижчу точність прогнозування у межах дослідження IEEE 14-bus, хоча attention-механізм дозволив моделі

визначати важливість окремих зв’язків між вузлами. Отримані результати свідчать про те, що для невеликих графів складність attention-механізму не завжди забезпечує покращення точності, однак такий підхід залишається перспективним для масштабних Smart Grid систем із більш складною топологією.

У процесі навчання було проаналізовано поведінку функції втрат для кожної моделі (рисунок 4.6). Графіки навчання демонструють поступове зменшення помилки прогнозування та стабілізацію loss-функції після декількох десятків епох.



Рисунок 4.6 – Функція втрат під час навчання моделей

GraphSAGE продемонструвала найшвидшу збіжність та найбільш плавний процес навчання. У випадку GAT спостерігалися більш помітні коливання функції втрат, що пояснюється високою чутливістю attention-механізму до шуму у синтетичних даних.

Окремо було проведено аналіз якості прогнозування часових рядів навантаження. Для цього виконувалося порівняння реальних та прогнозованих значень навантаження вузлів.

Отримані результати демонструють, що графові нейронні мережі здатні коректно відтворювати загальну динаміку зміни навантаження та успішно прогнозувати основні тренди часових рядів. Навіть за наявності випадкового шуму модель зберігає стабільність прогнозування та не демонструє різких відхилень.

Після завершення етапу прогнозування було проведено моделювання аварійної ситуації. Для цього у графі енергомережі виконувалося відключення двох ліній електропередач між вузлами 9–14 та 13–14. У результаті вузол 14 повністю втрачав зв’язок із основною частиною системи. Після аварії мережа розділилася на дві окремі компоненти зв’язності. Основна компонента містила вузли від 1 до 13, тоді як вузол 14 став ізольованим.

У процесі аналізу було встановлено, що після пошкодження система втратила частину навантаження, а окремі метрики графа перестали бути визначеними через розділення мережі. Зокрема, середня довжина найкоротшого шляху не могла бути обчислена для disconnected graph, що підтверджувало втрату глобальної зв’язності системи.

Після цього було активовано алгоритм реконфігурації мережі Після активації резервного ребра значення центральності знову зростає, що підтверджує відновлення ролі вузла у структурі енергосистеми. (рисунок 4.7).

Система виконувала пошук резервних зв’язків, здатних відновити зв’язність графа. У результаті було визначено, що додавання резервного ребра між вузлами 14 та 10 дозволяє повністю відновити структуру енергомережі.

Після реконфігурації граф знову перейшов у стан єдиної компоненти зв’язності, а коефіцієнт відновлення навантаження досяг значення 1.0 (рисунок 4.8). Це є повним відновлення працездатності системи та повернення всіх вузлів до спільної структури мережі.

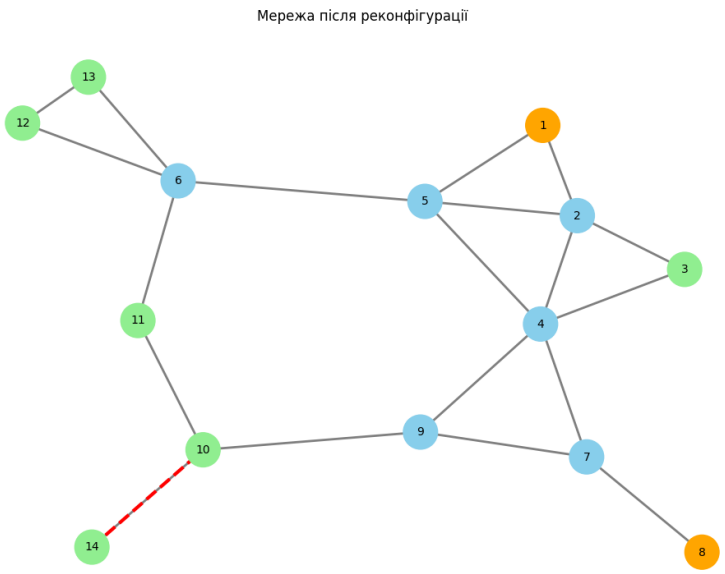


Рисунок 4.7 – Мережа після реконфігурації

Метрики стійкості та реконфігурації:

	Metric	Value
0	Total load before failure	259.000000
1	Supplied load after failure	244.100000
2	Supplied load after reconfiguration	259.000000
3	Supplied Load Ratio after failure	0.942471
4	Restored Load Ratio after reconfiguration	1.000000
5	Connected components after failure	2.000000
6	Connected components after reconfiguration	1.000000
7	Activated reserve lines	1.000000

Рисунок 4.8 – Метрики реконфігурації та відновлення мережі

Отримані результати підтвердили, що графове подання енергомережі дозволяє не лише прогнозувати навантаження, але й ефективно аналізувати аварійні ситуації та автоматично відновлювати структуру системи після пошкоджень. Використання графових нейронних мереж забезпечило можливість одночасного врахування часових та топологічних залежностей, що є важливою перевагою порівняно з класичними методами прогнозування.

4.4 Аналіз стійкості моделі при відмовах вузлів

Однією з головних характеристик сучасних енергетичних систем є їх здатність зберігати працездатність у випадку пошкодження окремих елементів мережі.

У реальних умовах причинами порушення роботи енергосистеми можуть бути перевантаження, фізичне пошкодження ліній електропередач, аварії на підстанціях або зовнішні впливи, що призводять до втрати зв’язності між компонентами мережі. Саме тому важливою частиною дослідження став аналіз стійкості графової моделі при аварійних ситуаціях.

У межах роботи стійкість системи оцінювалася шляхом моделювання відмов окремих елементів графа та подальшого аналізу змін його структури. Основним сценарієм стала аварія, пов’язана з відключенням двох ліній електропередач між вузлами 9–14 та 13–14.

Після видалення зазначених ребер вузол 14 повністю втратив зв’язок із мережею, у результаті чого граф розділився на дві компоненти зв’язності.

Отримані результати підтвердили, що навіть локальне пошкодження окремих ліній може суттєво впливати на структуру всієї системи. Незважаючи на те, що більшість вузлів залишилися з’єднаними між собою, ізоляція вузла 14 призвела до втрати частини навантаження та порушення глобальної зв’язності графа.

Для оцінки впливу аварії на структуру мережі було виконано аналіз компонент зв’язності (рисунок 4.9).

```
Відключені лінії: [(9, 14), (13, 14)]
Кількість компонент після збою: 2
Компоненти: [{1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13}, {14}]
```

Рисунок 4.9 – Компоненти графа після аварії

Результати показали, що після пошкодження мережа містить дві незалежні компоненти. Це свідчить про те, що вузол 14 є вразливим елементом структури IEEE 14-bus та залежить від обмеженої кількості зв’язків із основною мережею.

Окрему увагу було приділено аналізу центральності вузлів. Для цього використовувалися degree centrality, betweenness centrality та closeness centrality. Аналіз показав, що після аварії значення центральності вузла 14 зменшується до нуля, оскільки він повністю ізолюється від інших компонент системи.

Водночас центральність вузлів, що залишилися в основній компоненті графа, змінюється незначно, що свідчить про локальний характер пошкодження. Також було проведено аналіз загальних характеристик графа (рисунок 4.10). Після аварії середня довжина найкоротшого шляху перестала бути визначеною через розділення мережі на disconnected components. Це підтверджує втрату глобальної зв’язності та демонструє критичний вплив аварії на структуру системи.

Загальні метрики графа:

	Scenario	Nodes	Edges	Connected Components	Average Degree	Average Clustering	Average Shortest Path
0	Before Failure	14	20	1	2.857143	0.366667	2.373626
1	After Failure	14	18	2	2.571429	0.426190	NaN
2	After Reconfiguration	14	19	1	2.714286	0.426190	2.560440

Рисунок 4.10 – Загальні метрики графа

Після активації алгоритму реконфігурації було виконано повторний аналіз структури мережі. Додавання резервного ребра між вузлами 14 та 10 дозволило повністю відновити зв’язність графа.

Після реконфігурації значення центральності вузла 14 знову зросли, а мережа повернулася до стану єдиної компоненти зв’язності. Також було

відновлено можливість обчислення середньої довжини найкоротшого шляху, що свідчить про повернення системи до стабільного режиму роботи.

Важливим результатом стало те, що коефіцієнт відновлення навантаження після реконфігурації досяг значення 1.0, тобто система повністю відновила працездатність після аварії та забезпечила повернення всіх вузлів до спільної структури мережі.

Проведений аналіз підтвердив, що графове подання енергомережі дозволяє ефективно досліджувати стійкість системи до аварійних ситуацій, визначати критичні елементи мережі та автоматично виконувати реконфігурацію після пошкоджень. Отримані результати також демонструють перспективність використання графових нейронних мереж у задачах моніторингу та керування сучасними Smart Grid системами.

4.5 Порівняння GNN із класичними методами прогнозування

Одним із ключових завдань даного дослідження є оцінка ефективності графових нейронних мереж у порівнянні з традиційними методами прогнозування часових рядів. Для цього було проведено порівняльний аналіз між класичними підходами, зокрема моделями ARIMA та методами на основі графових нейронних мереж – GCN, GraphSAGE і GAT (рисунок 4.11).

Класичні моделі часових рядів орієнтовані переважно на аналіз часової динаміки одного сигналу. Вони ефективно працюють у задачах, де поведінка системи є відносно стабільною та може бути описана на основі попередніх значень ряду. У межах даної роботи ARIMA використовувалася як базовий метод порівняння для прогнозування навантаження окремих вузлів енергомережі.

Попри задовільну здатність ARIMA моделювати локальні часові залежності, результати експериментів показали низку суттєвих обмежень цього підходу. Насамперед модель не враховує структуру енергомережі та

взаємозв’язки між вузлами. Кожен часовий ряд аналізується ізольовано, без урахування того, що зміна навантаження в одному вузлі може впливати на стан сусідніх елементів системи.

Порівняння моделей:

	Model	MAE	RMSE	SMAPE
0	GCN	3.630929	5.277924	53.371399
1	GraphSAGE	1.634795	2.919021	35.598999
2	GAT	4.316759	7.823033	51.552635
3	ARIMA Node 3	4.259814	5.497740	3.130662

Рисунок 4.11 – Порівняння ARIMA, GCN, GraphSAGE та GAT

У випадку графових нейронних мереж прогнозування виконується з урахуванням топології мережі. Кожен вузол отримує інформацію від сусідніх елементів, що дозволяє моделі враховувати просторові залежності та структуру графа. Це забезпечує більш адаптивне прогнозування та кращу здатність реагувати на зміну конфігурації мережі.

Отримані результати показали, що графові нейронні мережі забезпечують вищу точність прогнозування у порівнянні з класичними методами часових рядів. Найкращі результати продемонструвала модель GraphSAGE, яка забезпечила найменші значення RMSE та SMAPE. Це пояснюється використанням індуктивного механізму агрегації, що дозволяє ефективно враховувати локальні особливості структури графа.

GCN також продемонструвала стабільні результати та перевищила точність ARIMA, однак поступилася GraphSAGE через більш простий механізм обробки сусідніх вузлів. Модель GAT показала нижчу точність прогнозування у межах досліджуваної топології IEEE 14-bus, однак attention-механізм дозволив краще інтерпретувати важливість окремих зв’язків у мережі.

Окремо було проведено аналіз поведінки моделей в умовах зміни структури мережі. Після моделювання аварії та втрати зв’язності класична модель ARIMA не могла врахувати зміну топології системи, оскільки працює виключно з часовими рядами окремих вузлів. Натомість графові нейронні мережі продовжували враховувати структуру мережі навіть після зміни її конфігурації.

Це є однією з найважливіших переваг графових моделей у задачах енергетики. У реальних енергосистемах зміна структури мережі відбувається постійно – через перевантаження, аварії, підключення нових джерел генерації або зміну режимів роботи системи. Класичні методи не здатні адаптуватися до таких змін без повного переналаштування моделі.

Графові нейронні мережі, навпаки, працюють безпосередньо зі структурою графа, що дозволяє їм автоматично реагувати на зміну топології та аналізувати вплив пошкоджень на стан системи.

Таким чином, результати дослідження підтвердили, що графові нейронні мережі є більш ефективним підходом для задач прогнозування навантаження та аналізу стійкості енергомережі. На відміну від класичних моделей часових рядів, GNN здатні одночасно враховувати часові та топологічні залежності, що забезпечує вищу точність прогнозування та кращу адаптацію до динамічних умов роботи системи.

4.6 Переваги графових підходів у задачах енергетики

Однією з головних особливостей сучасних енергетичних систем є складна структура взаємозв’язків між їх елементами. Робота кожного вузла залежить не лише від локального навантаження, а й від стану сусідніх компонентів, конфігурації ліній електропередач, режимів генерації та розподілу потужності у мережі. Саме тому класичні підходи, які аналізують кожен часовий ряд окремо, не здатні повноцінно описувати поведінку енергосистеми в умовах реальної експлуатації.

Графові підходи дозволяють подолати це обмеження завдяки використанню топологічного представлення мережі. У межах графової моделі кожен вузол енергосистеми розглядається як частина єдиної структури, а процес прогнозування виконується з урахуванням взаємозв’язків між елементами системи. Це забезпечує більш реалістичне представлення фізичних процесів, які відбуваються в енергомережі.

Однією з найважливіших переваг графових нейронних мереж є здатність одночасно враховувати часові та просторові залежності. На відміну від класичних моделей часових рядів, GNN аналізують не лише зміну навантаження у часі, але й вплив сусідніх вузлів на поточний стан системи. Це особливо важливо для енергетичних мереж, де перевантаження або аварія в одному вузлі можуть швидко впливати на інші компоненти мережі.

Важливою перевагою графових моделей є їх здатність працювати зі зміною топології мережі. У процесі дослідження було показано, що після аварійного відключення ліній між вузлами 9–14 та 13–14 графова модель коректно відобразила втрату зв’язності системи та дозволила виконати реконфігурацію мережі.

Класичні моделі прогнозування не мають подібного механізму адаптації, оскільки працюють лише з часовими рядами та не враховують структуру мережі. У випадку зміни топології такі моделі потребують повного переналаштування або повторного навчання.

Ще однією важливою перевагою графових підходів є можливість аналізу структурних характеристик мережі. Використання метрик центральності, асортативності та гомофільності дозволяє визначати критичні вузли системи, оцінювати стійкість мережі та прогнозувати потенційні точки виникнення аварій.

У процесі експериментів було встановлено, що ізоляція вузла 14 призводить до повної втрати його центральності, тоді як після реконфігурації значення центральності знову відновлюються. Це

підтверджує здатність графових моделей не лише прогнозувати навантаження, але й аналізувати структурний стан енергомережі.

Окремою перевагою GNN є можливість масштабування на великі енергетичні системи. Використання GraphSAGE та механізмів neighbor sampling дозволяє працювати з графами, що містять тисячі вузлів, без необхідності обробки всієї структури мережі одночасно. Це є особливо важливим для сучасних Smart Grid систем, які характеризуються високою динамічністю та великою кількістю взаємопов’язаних елементів.

Крім цього, графові нейронні мережі можуть інтегруватися з іншими методами штучного інтелекту, включаючи reinforcement learning, anomaly detection та системи автоматизованого керування. Це відкриває можливість створення автономних енергетичних систем, здатних самостійно прогнозувати зміни навантаження, реагувати на аварійні ситуації та оптимізувати конфігурацію мережі в реальному часі.

Таким чином, результати дослідження підтверджують, що графові підходи є перспективним напрямом розвитку інтелектуальних систем керування енергомережами. Їх використання дозволяє більш точно описувати структуру енергосистеми, підвищувати точність прогнозування та забезпечувати адаптивність системи до зміни умов її роботи.

4.7 Можливі напрями вдосконалення системи

Незважаючи на отримані результати та підтверджену ефективність графових нейронних мереж у задачах прогнозування та реконфігурації енергомережі, розроблена система має значний потенціал для подальшого розвитку та вдосконалення.

Одним із основних напрямів розвитку є перехід від тестової топології IEEE 14-bus до більших та складніших енергетичних систем. Використання моделей IEEE 30-bus, IEEE 57-bus або IEEE 118-bus дозволить дослідити поведінку графових нейронних мереж у масштабних Smart Grid системах із

більш складною структурою зв’язків та великою кількістю вузлів. Це також дозволить оцінити ефективність моделей у реалістичніших умовах функціонування енергетичної інфраструктури.

Перспективним напрямом є використання реальних часових рядів навантаження замість синтетичних даних. У межах даного дослідження синтетична генерація дозволила створити контрольоване середовище для тестування моделей, однак використання реальних даних енергоспоживання дало б можливість оцінити ефективність системи у практичних умовах експлуатації.

Подальшого розвитку потребує й механізм реконфігурації мережі. У межах роботи використовувався відносно простий алгоритм активації резервних ліній електропередач, однак у реальних енергосистемах процес реконфігурації повинен враховувати значно більшу кількість параметрів, включаючи баланс потужності, обмеження пропускної здатності ліній, втрати енергії та економічні фактори.

Одним із перспективних напрямів є інтеграція reinforcement learning для автоматичного вибору оптимальної конфігурації мережі. Такий підхід дозволив би системі не лише відновлювати зв’язність графа, але й знаходити оптимальні сценарії роботи мережі залежно від поточного стану системи.

Також перспективним є використання динамічних графових нейронних мереж (Temporal GNN), які поєднують аналіз часових рядів із динамічною зміною структури графа. На відміну від статичних GNN, такі моделі дозволяють враховувати зміну топології мережі у часі та більш точно моделювати поведінку реальних енергосистем.

Окремої уваги заслуговує проблема роботи моделей в умовах високого рівня шуму та неповноти даних. У реальних Smart Grid системах датчики можуть передавати неповну або пошкоджену інформацію, що створює додаткові труднощі для прогнозування. Подальший розвиток системи може включати інтеграцію механізмів anomaly detection та probabilistic learning для роботи в умовах невизначеності.

Також перспективним напрямом є розширення набору метрик аналізу графа. У межах даної роботи використовувалися центральність, асортативність та гомофільність, однак для більш глибокого аналізу стійкості енергомережі можуть застосовуватися спектральні характеристики графа, community detection та методи аналізу потокорозподілу.

Розроблена система може бути інтегрована у компоненти Smart Grid та системи диспетчерського керування енергомережами. Використання графових нейронних мереж в реальному часі дозволить створювати адаптивні інтелектуальні системи керування енергетичною інфраструктурою.

ВИСНОВКИ

Таким чином, у кваліфікаційній роботі досліджено проблему прогнозування навантаження та реконфігурації енергомережі в умовах невизначеності із використанням графових моделей та графових нейронних мереж. Актуальність дослідження обумовлена стрімким розвитком сучасних енергетичних систем, інтеграцією відновлюваних джерел енергії, ускладненням структури Smart Grid мереж та необхідністю забезпечення їхньої стійкої роботи в умовах аварійних ситуацій і нестабільного навантаження.

У процесі виконання роботи було проведено аналіз предметної галузі та сучасних підходів до прогнозування навантаження в енергомережах. Досліджено класичні методи часових рядів, зокрема ARIMA, SARIMA та Prophet, а також сучасні методи машинного навчання й глибинного навчання. Встановлено, що традиційні підходи мають обмеження у задачах енергетики через відсутність урахування топологічної структури мережі та взаємозалежностей між її елементами [19].

У роботі розглянуто теоретичні основи графових нейронних мереж та принципи їх функціонування. Проаналізовано архітектури GCN, GraphSAGE та GAT, механізм передачі інформації між вузлами графа, а також метрики аналізу графових структур, серед яких центральність, асортативність та гомофільність. Визначено, що графові підходи дозволяють більш точно описувати структуру енергомережі та враховувати взаємний вплив вузлів у процесі прогнозування [19].

У межах практичної частини роботи було реалізовано програмний прототип системи у середовищі Python із використанням бібліотек PyTorch Geometric та NetworkX. Основою дослідження стала тестова енергомережа IEEE 14-bus, яку було формалізовано у вигляді графа. Для навчання моделей згенеровано синтетичні часові ряди навантаження, що дозволило

змоделювати роботу енергосистеми в умовах невизначеності та нестабільності споживання.

У роботі реалізовано та протестовано моделі GCN, GraphSAGE та GAT. Проведене порівняння результатів показало, що графові нейронні мережі забезпечують більш ефективне прогнозування навантаження у порівнянні з класичними моделями часових рядів. Найкращі результати продемонструвала модель GraphSAGE, яка забезпечила стабільне навчання та найменші значення помилки прогнозування.

Окрему увагу приділено моделюванню аварійних ситуацій та реконфігурації енергомережі. У процесі експериментів було змодельовано аварію шляхом відключення ліній електропередач між вузлами 9–14 та 13– 14, що призвело до ізоляції вузла 14 та втрати зв’язності мережі. Для відновлення працездатності системи реалізовано алгоритм реконфігурації, який дозволив відновити зв’язність графа шляхом активації резервної лінії між вузлами 14 та 10. У результаті коефіцієнт відновлення навантаження досяг значення 1.0, що свідчить про повне відновлення структури мережі.

Отримані результати підтвердили ефективність використання графових нейронних мереж у задачах прогнозування навантаження, аналізу стійкості та реконфігурації енергомережі. Використання графових моделей дозволяє одночасно враховувати часові та топологічні залежності, що є важливою перевагою у порівнянні з класичними методами аналізу часових рядів.

Практичне значення роботи полягає у створенні програмного прототипу інтелектуальної системи, здатної прогнозувати навантаження, аналізувати аварійні ситуації та виконувати реконфігурацію енергомережі в умовах зміни її структури. Отримані результати можуть бути використані як основа для подальшого розвитку Smart Grid систем, автоматизованих платформ моніторингу та інтелектуального керування сучасними енергетичними мережами.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Adversarial caching training: unsupervised inductive network representation learning on large-scale graphs / J. Chen et al. *IEEE Transactions on neural networks and learning systems*. 2021. P. 1–12. URL: https://doi.org/10.1109/tnnls.2021.3084195 (date of access: 01.05.2026).

2. A method for node importance evaluation in power systems based on graph neural networks / W. Xia et al. *2025 2nd international conference on smart grid and artificial intelligence (SGAI)*, Changsha, China, 21–23 March 2025. P. 188–192. URL: https://doi.org/10.1109/sgai64825.2025.11009963 (date of access: 07.04.2026).

3. Graph neural solver for power systems / B. Donon et al. *2019 International joint conference on neural networks (IJCNN)*, Budapest, Hungary, 14–19 July 2019. 2019. URL: https://doi.org/10.1109/ijcnn.2019.8851855 (date of access: 17.04.2026).

4. *Matpower. IEEE Test cases*. URL: https://matpower.org/docs/ref/matpower4.1/case14.html (date of access: 06.05.2026).

5. Neural networks for power flow: graph neural solver / B. Donon et al. *Electric power systems research*. 2020. Vol. 189. P. 106547. URL: https://doi.org/10.1016/j.epsr.2020.106547 (date of access: 20.04.2026).

6. Separated graph neural networks for recommendation systems / J. Sun et al. *IEEE Transactions on industrial informatics*. 2022. P. 1–11. URL: https://doi.org/10.1109/tii.2022.3194659 (date of access: 27.04.2026).

7. Smart grid: technology and applications / N. Jenkins et al. Wiley & Sons, Incorporated, John, 2012. 320 p.

8. Taylor S. J., Letham B. Forecasting at scale. The american statistician. 2018. Vol. 72, № 1. P. 37–45. URL: https://doi.org/10.1080/00031305.2017.1380080 (date of access: 15.04.2026).

9. Time series analysis, *Forecasting, and control* / E. R. Ziegel et al. Technometrics. 1995. Vol. 37, № 2. P. 238. URL: https://doi.org/10.2307/1269640 (date of access: 03.05.2026).

10. Sparse graph attention networks. *IEEE Transactions on knowledge and data engineering*. 2021. URL: https://doi.org/10.1109/tkde.2021.3072345 (date of access: 07.05.2026).

11. ARIMA vs SARIMA vs SARIMAX vs Prophet for time series forecasting. *Medium*. URL: https://kishanakbari.medium.com/arima-vs-sarima-vs-sarimax-vs-prophet-for-time-series-forecasting-a59d3cc932a3 (date of access: 18.04.2026).

12. Chikina N., Antonova I. Порівняльний аналіз часових рядів. *Системи управління, навігації та зв'язку. Збірник наукових праць*. 2026. Т. 1, № 83. С. 126–130. URL: https://doi.org/10.26906/sunz.2026.1.126 (дата звернення: 17.04.2026).

13. *SARIMA. GeeksforGeeks*. URL: https://www.geeksforgeeks.org/machine-learning/sarima-seasonal-autoregressive-integrated-moving-average/ (date of access: 19.04.2026).

14. Graph neural networks: an efficient energy solution for structured data analysis. *Heptalytics your AI powered payment fraudfighter & AML/CFT assistant*. URL: https://www.heptalytics.ai/graph-neural-networks-an-efficient-energy-solution-for-structured-data-analysis (date of access: 12.04.2026).

15. Learning graph structure via graph convolutional networks / Q. Zhang et al. Pattern recognition. 2019. Vol. 95. P. 308–318. URL: https://doi.org/10.1016/j.patcog.2019.06.012 (date of access: 29.01.2026).

16. Montgomery D. C., Jennings C. L., Kulahci M. Introduction to Time Series analysis and forecasting. Wiley & Sons, Incorporated, John, 2015. 672 p.

17. What is a graph neural network. *IBM*. URL: https://www.ibm.com/think/topics/graph,Graph%20neural%20networks,connectivity%20of%20the%20input%20graph (date of access: 21.04.2026).

18. Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: comparison with machine learning approaches / S. Bouktif et al. *Energies*. 2018. Vol. 11, no. 7. P. 1636. URL: https://doi.org/10.3390/en11071636 (date of access: 12.03.2026).

19. Xiao F., Ai Q. Electricity theft detection in smart grid using random matrix theory. *IET Generation, transmission & distribution*. 2018. Vol. 12, no. 2. P. 371–378. URL: https://doi.org/10.1049/iet-gtd.2017.0898 (date of access: 15.04.2026).