

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет комп'ютерної інженерії та управління  
(повна назва)

Кафедра електронних обчислювальних машин  
(повна назва)

**КВАЛІФІКАЦІЙНА РОБОТА**  
**Пояснювальна записка**

Рівень вищої освіти другий (магістерський)

Модель системи керування розподілом електричної  
енергії з використанням машинного навчання

(тема)

Виконав:

студент II курсу, групи СПМ-22-4  
Павлов О.С.  
(прізвище, ініціали)

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

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

Освітня програма Системне програмування  
(повна назва освітньої програми)

Керівник: проф. Торба А.А.  
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри ЕОМ

(підпис)

Коваленко А.А.

(прізвище, ініціали)

2024 р.

Харківський національний університет радіоелектроніки

Факультет \_\_\_\_\_ комп'ютерної інженерії та управління  
Кафедра \_\_\_\_\_ електронних обчислювальних машин  
Рівень вищої освіти \_\_\_\_\_ другий (магістерський)  
Спеціальність \_\_\_\_\_ 123 «Комп'ютерна інженерія»  
(код і повна назва)  
Тип програми \_\_\_\_\_ освітньо-наукова  
(освітньо-професійна або освітньо-наукова)  
Освітня програма \_\_\_\_\_ Системне програмування  
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри \_\_\_\_\_  
(підпис)

“ \_\_\_\_\_ ” \_\_\_\_\_ 20\_\_ р.

**ЗАВДАННЯ**

**НА КВАЛІФІКАЦІЙНУ РОБОТУ**

студенту \_\_\_\_\_ Павлову Олександрю Сергійовичу  
(прізвище, ім'я, по батькові)

1. Тема роботи \_\_\_\_\_ Модель системи керування розподілом електричної енергії  
з використанням машинного навчання

затверджена наказом по університету від “ 01 ” квітня 2024 р. № 257 Ст

2. Термін подання студентом роботи до екзаменаційної комісії \_\_\_\_\_ 15 червня 2024 р.

3. Вхідні дані до роботи \_\_\_\_\_ 1) типова розподільча енергомережа;  
\_\_\_\_\_ 2) розробка засобів керування балансуванням енергопотоків;  
\_\_\_\_\_ 3) використання системи на основі SCADA.

4. Перелік питань, що потрібно опрацювати у роботі \_\_\_\_\_

- \_\_\_\_\_ 1) аналіз проблеми;
- \_\_\_\_\_ 2) аналіз енергосистеми як об'єкта керування;
- \_\_\_\_\_ 3) огляд підходів до використання ML;
- \_\_\_\_\_ 4) розробка моделі;
- \_\_\_\_\_ 5) проведення експериментальних досліджень;
- \_\_\_\_\_ б) висновки.

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (слайдів) \_\_\_\_\_

Слайд-презентація – 12 слайдів \_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

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

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

### КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Аналіз проблеми	02.04.24-08.04.24	
2	Аналіз енергосистеми як об'єкта керування	09.04.24-16.04.24	
3	Огляд підходів до використання ML	17.04.24-22.04.24	
4	Розробка моделі системи	23.04.24-06.05.24	
5	Проведення експериментів	07.05.24-23.05.24	
6	Оформлення матеріалів кваліфікаційної роботи	24.05.24-03.06.24	
7	Подання кваліфікаційної роботи керівникові та її попередній захист	04.06.24-07.06.24	
8	Подання кваліфікаційної роботи на рецензування	08.06.24-12.06.24	

Дата видачі завдання 01 квітня 2024 р.

Студент \_\_\_\_\_  
(підпис)

Керівник роботи \_\_\_\_\_  
(підпис)

проф. Торба А.А.  
(посада, прізвище, ініціали)

## РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 76 с., 14 рис., 4 табл., 1 дод., 44 джерела.

ЕЛЕКТРОМЕРЕЖІ, ІНТЕЛЕКТУАЛЬНИЙ АНАЛІЗ ДАНИХ, ІНТЕРНЕТ РЕЧЕЙ, МАШИННЕ НАВЧАННЯ, ПРОГНОЗНІ МОДЕЛІ, ШТУЧНИЙ ІНТЕЛЕКТ, SCADA.

Метою кваліфікаційної роботи є побудова моделі системи керування розподілом електричної енергії з використанням машинного навчання.

Запропоновані точні та ефективні моделі оцінки перерозподілу навантаження. З урахуванням того, що існує декілька методів моделювання, запропоновані в цій роботі методи моделювання базуються на моделях машинного навчання: множинна лінійна регресія, нелінійна регресія та моделі нейронної мережі класифікатора.

Новизна цієї роботи полягає в тому, що вона впроваджує відмовостійкий підхід, який спирається на машинне навчання та систему диспетчерського контролю та збору даних (SCADA).

## ABSTRACT

Master's thesis: 76 pages, 14 figures, 4 tables, 1 appendix, 44 sources.

ARTIFICIAL INTELLIGENCE, INTELLIGENT DATA ANALYSIS, INTERNET OF THINGS, MACHINE LEARNING, POWER GRIDS, PREDICTIVE MODELS, SCADA.

The purpose of this qualification work is to build a model of the electrical energy distribution management system using machine learning.

Accurate and effective load redistribution assessment models are proposed. Given that there are several modeling methods, the modeling methods proposed in this paper are based on machine learning models: multiple linear regression, nonlinear regression, and neural network models-based classifier.

The novelty of this work is that it implements a fault-tolerant approach that relies on machine learning and a supervisory control and data acquisition (SCADA) system.

## ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ .....	8
ВСТУП .....	10
1 АНАЛІЗ ПРОБЛЕМИ .....	12
1.1 Загальні відомості .....	12
1.2 Мережі розподілу електроенергії на основі SCADA .....	17
1.3 Основи електроенергетичних систем.....	20
1.4 Модель енергосистеми .....	22
2 АНАЛІЗ ЕНЕРГОСИСТЕМИ ЯК ОБ'ЄКТА КЕРУВАННЯ .....	24
2.1 Проблема потоку електроенергії.....	24
2.2 Оптимальний потік потужності.....	27
2.3 Оцінка стану .....	29
2.4 Загальні міркування щодо ML для аналізу системи розподілу електроенергії .....	32
2.5 Дані системи розподілу електроенергії .....	34
3 ПІДХОДИ ДО ВИКОРИСТАННЯ ML .....	37
3.1 Основи навчання .....	37
3.1.1 Функція втрат .....	39
3.1.2 Вимоги до даних .....	41
3.1.3 Оцінка продуктивності моделі .....	42
3.2 Таксономія парадигм навчання .....	43
4 МОДЕЛЬ СИСТЕМИ РОЗПОДІЛУ ЕЛЕКТРОЕНЕРГІЇ .....	46
4.1 Базові відомості .....	46
4.2 Модель системи.....	48
4.3 Архітектура системи.....	49
4.4 Компоненти системи.....	50
4.5 Методологія .....	52

4.6 Результати .....	55
4.6.1 Регресійні моделі MATLAB.....	56
4.6.2 Модель нейронної мережі Python.....	56
4.6.3 Точність моделі .....	59
ВИСНОВКИ.....	61
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ .....	63
ДОДАТОК А ГРАФІЧНИЙ МАТЕРІАЛ КВАЛІФІКАЦІЙНОЇ РОБОТИ .....	68

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ  
І ТЕРМІНІВ

ШІ – штучний інтелект

ANN – штучна нейронна мережа (англ., Artificial neural network)

DER – розподілений енергетичний ресурс (англ., Distributed energy resource)

DNN – глибока нейронна мережа (англ., Deep neural network)

D-OPF – оптимальний потік розподіленої потужності (англ., Distribution optimal power flow)

DSSE – оцінка стану системи розподілу (англ., Distribution system state estimation)

EV – електромобіль (англ., Electric vehicle)

FLISR – локалізація несправності, усунення та відновлення роботи (англ., Fault location, isolation and service restoration)

GAN – генеративна змагальна мережа (англ., Generative adversarial network)

GNN – графова нейронна мережа (англ., Graph neural network)

GP – гаусівський процес (англ., Gaussian process)

k-NN – k-найближчі сусіди (англ., k-nearest neighbors)

ML – машинне навчання (англ., Machine learning)

OPF – оптимальний потік потужності (англ., Optimal power flow)

PCA – аналіз головних компонент (англ., Principal components analysis)

PES – силові та енергетичні системи (англ., Power and energy systems)

PMU – одиниця вимірювання фазора (англ., Phasor measurement unit)

PV – фотоелектричний (англ., Photovoltaic)

SCADA – диспетчерський контроль і збір даних (англ., Supervisory control and data acquisition)

SE – оцінювання стану (англ., State estimation)

SSL – напівконтрольоване навчання (англ., Semi-supervised learning)

SVM – опорні векторні машини (англ., Support vector machines)

V2G – взаємодія транспортного засобу з мережу (англ., Vehicle-to-grid)

WLS – зважений найменший квадрат (англ., Weighted least square)

## ВСТУП

Електрика відіграє життєво важливу роль у нашому повсякденному житті. Однак через швидке зростання населення, а також широке поширення цивілізації в різних географічних місцях розподіл електроенергії стикається з багатьма проблемами. Наприклад, якщо існуючій традиційній електричній мережі більше 50 років, то необхідні різні оновлення для ефективного задоволення зростаючих вимог, мінімізації втрат, усунення несправностей і транспортування електроенергії.

Тому залучення інформаційних технологій до електричної мережі вважається перспективним рішенням для вирішення багатьох недоліків традиційних електричних мереж. В результаті з'явилася концепція Smart Grid, яка має багато цікавих властивостей. Розумні електромережі включають різні ефективні технології вимірювання, які використовують датчики, системи зв'язку та системи керування в поточних електромережах. Таким чином, досягаються різні покращення в оптимізації активів, операційної ефективності та альтернатив зберігання. Крім того, інтелектуальні мережі об'єднують широкий спектр додатків, що містять програмні та апаратні технології, які дозволяють службам взаємодіяти з поточною електричною мережею та інтелектуально керувати нею.

Застосування машинного навчання (ML) до енергетичних систем (PES) досліджується з приголомшливою швидкістю, що призвело до значної кількості останніх доповнень до літератури. У міру розвитку інфраструктури електроенергетичних систем зростає інтерес до впровадження методів машинного навчання на PES. Однак, незважаючи на зростаючий інтерес, обмежена кількість зареєстрованих реальних застосувань свідчить про те, що розрив між дослідженнями та практикою ще не повністю подолано.

З метою допомогти висвітлити області, де вказану прогалину можна скоротити у цій роботі обговорюються проблеми та можливості розробки та

адаптації методів машинного навчання для сучасних систем електроенергії, з особливим акцентом на системах розподілу електроенергії. Ці системи відіграють вирішальну роль у трансформації сектору електроенергетики та адаптації нових розподілених технологій для пом'якшення наслідків зміни клімату та прискорення переходу до сталого енергетичного майбутнього.

Мета роботи полягає не в тому, щоб надати вичерпний огляд сучасної літератури, а радше в тому, щоб заохочувати міждисциплінарні дослідження в цій галузі, що швидко розвивається. З цією метою в роботі обговорюються способи, за допомогою яких ML може сприяти вирішенню нових операційних проблем, з якими стикаються системи розподілу електроенергії, і визначаються відповідні сфери застосування, які є прикладом потенційного внеску ML у найближчій перспективі. У той самий час обговорюються ключові міркування щодо практичного впровадження ML у системах розподілу електроенергії, а також пропозиції щодо кількох потенційних майбутніх напрямків.

# 1 АНАЛІЗ ПРОБЛЕМИ

## 1.1 Загальні відомості

Країни в усьому світі встановили обов'язкові цілі щодо зниження викидів парникових газів для боротьби з найгіршими наслідками зміни клімату. У рамках цих кліматичних заходів зусилля з декарбонізації сектору електроенергетики значною мірою залежать від масштабного використання відновлюваних джерел енергії, переважно вітру та сонця. Досягнення цільових показників скорочення викидів парникових газів також вимагає переведення попиту на транспортну енергію з викопного палива на електрику за допомогою масштабної електрифікації транспортних засобів та підтримки зарядної інфраструктури, що призводить до значного збільшення попиту на електроенергію. Оскільки попит на електроенергію зростає, а вимоги до декарбонізації зберігаються, важливість і складність систем розподілу електроенергії зростає.

В останні роки різко зросла інтеграція малих розподілених енергетичних ресурсів (DER), таких як сонячні фотоелектричні (PV) та електричні транспортні засоби (EV), у системи розподілу електроенергії. Однак, через їхню внутрішню мінливість, невизначеність і обмежену контрольованість, ці нові активи та технології створюють нові проблеми для надійної та безпечної роботи мереж розподілу електроенергії. Зростаюча кількість DER демонструє обмеження існуючих аналітичних інструментів для експлуатації та управління електричними розподільними мережами, насамперед через те, що ці інструменти були розроблені для традиційних розподільних мереж, де невизначеність виникає лише через профілі споживання, а електроенергія подається переважно від системи передачі до системи розподілу.

У той же час мінливість і невизначеність від погоднозалежної генерації

відновлюваної енергії, а також обмежене спостереження та видимість операцій розподільчої мережі створюють нові виклики. Ці виклики стануть більш серйозними в майбутніх мережах без вдосконалених методологій експлуатації та планування для підвищення операційної гнучкості та гарантування безпеки мережі, таким чином підтримуючи стабільні напруги та частоти [1]. Значну увагу дослідників привернули штучний інтелект (AI) і, зокрема, машинне навчання (ML) як багатообіцяючі рішення для вирішення цих проблем. Передбачається, що впровадження рішень ML доповнить або потенційно навіть замінить традиційні, давно усталені підходи до моделювання на основі фізики, які використовуються в різних аспектах аналізу енергосистеми. У цьому контексті додатки ML охоплюють майже всі сфери інтересів, включаючи виробництво, передачу, розподіл і споживання, і поширюються на об'єднані системи енергетичної інфраструктури, такі як опалення, газ і транспорт. Подібним чином програми ML в енергетичних системах можуть охоплювати широкий діапазон часових масштабів, починаючи від субсекундних інтервалів для перехідної стабільності до десятиліть для планування.

Традиційне уявлення про процес машинного навчання включає алгоритм навчання, який використовує вхідні дані для пошуку прихованих шаблонів і структур у даних, отримання нових ідей із даних або автоматичного прогнозування. Коли апріорна інформація (наприклад, початкові умови) і знання (наприклад, фізичні та математичні принципи) включені в навчальний процес, те, що раніше керувалося виключно даними (також зазвичай називають фізико-агностичним або безмодельним) тепер стає гібридною методологією (також зазвичай називають фізично-інформованим або науковим MM), більш придатною для інженерних застосувань (рисунок 1.1). Конкретним прикладом цієї нової методології навчання є категорія алгоритмів глибокого навчання, які називають нейронними мережами на основі фізики [2]. Наприклад [3], є ретельний огляд застосування нейронних мереж, заснованих на фізиці, у сфері енергетичних

систем, що робить його цінним прочитанням для тих, хто цікавиться цією темою.

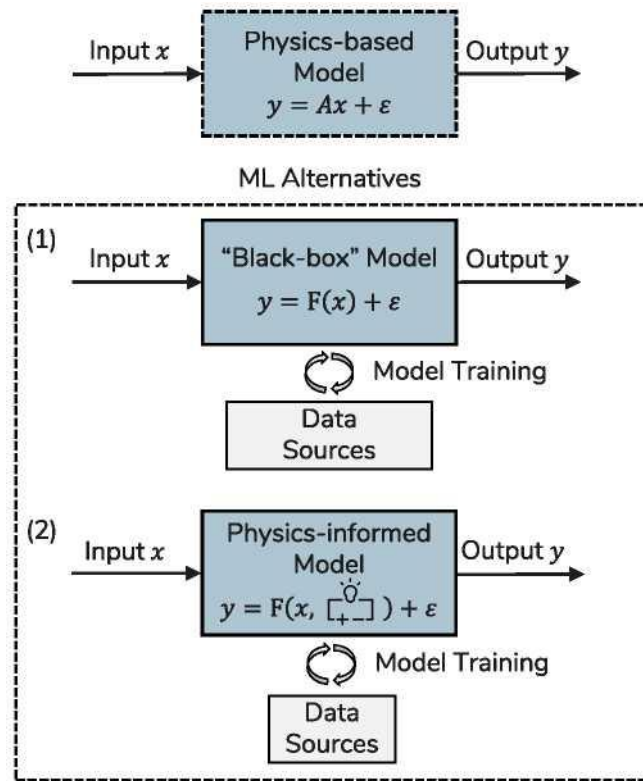


Рисунок 1.1 – Альтернативи машинного навчання (1) і (2) моделям на основі фізики. Фізичні моделі (2), на відміну від моделей чорної скриньки (1), потребують менше даних, що відображається в меншому розмірі скриньки, що стосується джерел даних

Загалом, ML охоплює широкий спектр методів, які можуть навчатися на основі:

- експериментальних даних (у випадку PES це часто дані, отримані з обчислювального моделювання);
- даних спостережень, що описують фізичні процеси в системі (наприклад, вимірювання енергосистеми);
- обох (спостереження та експериментальні/симуляційні дані), для побудови прогнозних або пояснювальних моделей.

Таким чином, ці методи можуть запропонувати багато переваг

порівняно з традиційними методологіями планування, експлуатації та контролю енергосистеми. Деякі приклади включають, але не обмежуються цим:

- зменшення обчислювальної складності для розв'язання проблем, заснованих на оптимізації, поширених в енергетичних системах;
- більш висока точність у лінійному моделюванні нелінійних рівнянь потоку потужності та інших апроксимацій лінійних функцій, що призводить до покращеної точності рішення та/або скорочення часу обчислення;
- здатність обробляти та аналізувати великі обсяги вимірювань, зібраних з різнорідних джерел даних, щоб отримати цінну інформацію або прогнози з таких вимірюваних даних;
- здатність керувати невірними поставленими проблемами;
- більш обґрунтоване прийняття рішень в умовах зростаючої невизначеності через DER;
- інтелектуальна підтримка діагностики та моніторингу несправностей у складних мережах розподілу;
- вивчення функцій, які важко змодельовати, таких як поведінка споживачів для механізмів реагування на попит, які не забезпечують замкнуту систему рівнянь.

Деякі потенційні сфери застосування ML у системах розподілу електроенергії наведені на рисунку 1.2.

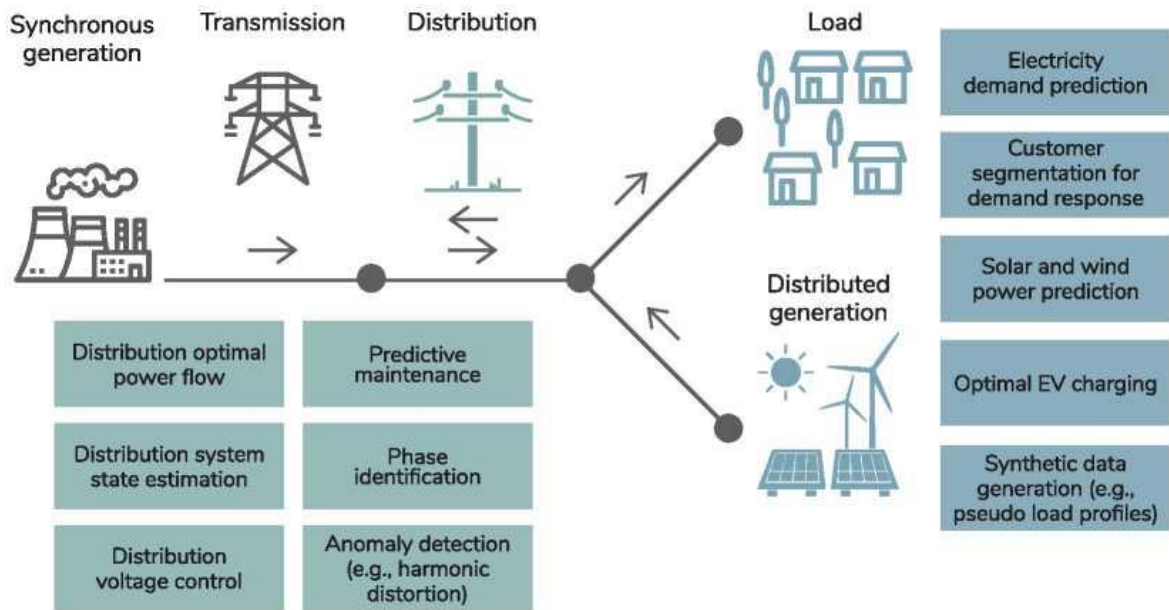


Рисунок 1.2 – Зміна операційної парадигми енергосистеми з відомими програмами машинного навчання в системах розподілу електроенергії

Постійний прогрес у галузі штучного інтелекту був зумовлений появою величезних обсягів даних і використанням високопродуктивних паралельних обчислень із використанням апаратних прискорювачів штучного інтелекту, таких як графічні процесори. Останні досягнення в ML характеризуються розробкою нових алгоритмів, зокрема в глибоких нейронних мережах (DNN) [4] і графових нейронних мережах (GNN) [5]. Оскільки AI/ML розвивається з безпрецедентною швидкістю, це, ймовірно, матиме значний вплив на те, як експлуатуються та плануються енергосистеми.

Незважаючи на активні дослідження, присвячені застосуванню найсучасніших методів машинного навчання для вирішення проблем енергосистеми, часто не приділяється уваги оцінці придатності техніки для вирішення конкретної проблеми. Наприклад, такі інтенсивні методи, як DNN, можуть не підходити для вирішення проблем системи живлення, коли великі обсяги даних недоступні. Подібним чином, хоча GNN демонструють багатообіцяючі переваги, для їх використання в системах розподілу електроенергії ще потрібно подолати багато перешкод [6]. З метою усунення

цієї прогалини, ця робота має надати розуміння важливих тем, що стосуються:

- ML для систем електроенергії з особливим акцентом на електричних розподільних мережах;

- викликів, унікальних для цієї міждисциплінарної галузі досліджень.

На відміну від попередніх робіт, які або широко охоплювали ці теми, або були спрямовані на конкретні області застосування чи методології машинного навчання, ця робота зосереджена на загальних зусиллях з машинного навчання, необхідних для систем розподілу електроенергії. Вона не має на меті бути повним оглядом усіх правдоподібних застосувань або ретельним оглядом літератури, оскільки це було б надто амбітним. Натомість тут обговорюються додатки в системі розподілу, які можуть отримати вигоду від широкого спектру концепцій і методів машинного навчання шляхом визначення відповідних областей застосування. Мета полягає в тому, щоб сприяти та стимулювати міждисциплінарні дослідження між двома дисциплінами для спрямування майбутніх досліджень та реалізації потенціалу машинного навчання в системах розподілу електроенергії.

## 1.2 Мережі розподілу електроенергії на основі SCADA

Відмовостійкі системи розподілу електроенергії привертають все більшу увагу дослідників, особливо системи розподілу на основі SCADA. Одне із досліджень [7] запропонувало SCADA на основі IoT, інтегровану з Fog для автоматизації розподілу. Запропонована система піклується про справність полюсного трансформатора, використання споживачів, управління відключеннями та контроль якості електроенергії. Для того, щоб зменшити затримку та пропускну здатність Інтернету, система підтримується туманними обчисленнями, які виконують потокову аналітику в реальному часі.

Представлено [8] проект прототипу та впровадження компонента

генерації знань у реальному часі на основі багатоагентного підходу, який можна застосовувати в промислових системах SCADA. Також обговорюються проблеми та ефективність інтеграції розумної SCADA та розумної мережі, таким чином обговорюючи використовувану(і) архітектуру(и), а також деякі реалізовані заходи для захисту цих архітектур у міру їхнього зростання. Крім того, розглядається зменшення складності впровадження багатьох стандартів, передбачених іншими стандартами та органами управління, як засіб досягнення практичного управління. Крім того, представлена [9] модель системи виявлення вторгнень, яка спеціально розроблена для мереж Modbus/TCP. Представлений підхід спирається на ключове обговорення, яке враховує дуже періодичний трафік Modbus від і до конкретного PLC. Таким чином, канал PLC інтерфейсу «людина-машина» кожної машини може бути змодельований за допомогою власного унікального детермінованого кінцевого автомата. В інших дослідженнях підходи до атак кібербезпеки розширюються з урахуванням підходів для систем керування в електроенергетиці. Наприклад, для оцінки струсу фізичної системи після успішної атаки на контур автоматичного керування генерацією використовуються величина відхилення частоти та дисбаланс генерації навантаження. Крім того, деякі дослідники використовували підходи машинного навчання у своїх дослідженнях. Запропоновано [10] методологію, яка створює автоматизовані системи виявлення несправностей і елементи керування, які потрібно налаштувати за допомогою методів машинного навчання. Цей підхід ґрунтується на об'єднанні даних датчиків і кодуванні інженерних знань, які є загальними для прикладної системи, але не залежать від конкретного розгортання.

Розглядаються [11] поточні проблеми безпеки, пов'язані з будинками, споживання електроенергії яких контролюється, регулюється та, нарешті, виставляється споживачам. Запропоновано модель машинного навчання, яка базується на графах і використовує невелику кількість навчальних даних. Модель може виявити несправність і визначити можливий тип несправності.

Представлено нову структуру графової згорткової мережі (GCN) для визначення місця пошкодження в мережах розподілу електроенергії. Запропонований підхід координує численні вимірювання на різних шинах з урахуванням топології системи.

Також було запропоновано [12] інтелектуальну активну відмовостійку систему на основі глибокої нейронної мережі. Запропонований алгоритм використовує нейронну мережу таким чином, що коли несправності немає, NN навчає кожен підфільтр. Коли виникає несправність, він прогнозує дані про час несправності. Ці дані будуть використані для заміни помилкових даних у головному фільтрі для злиття. В інших дослідженнях показано важливість використання методів штучного інтелекту в інтелектуальній мережі. Ці методи забезпечують потужні інструменти для діагностики несправностей і відмовостійкості. Також надається короткий опис кількох прикладів програм на основі ШІ. Слід зазначити метод [13] виконання точної кластеризації вхідних даних за допомогою глибокої моделі згорткової нейронної мережі (CNN). У роботі обговорювалося прогнозування електричного навантаження та оптимізація розподілу енергетичних ресурсів у розумній мережі.

Крім того, для прогнозування та оцінки розподілу потужності використовуються різні методи моделювання. Були запропоновані [14, 15] моделі нелінійних інтелектуальних мереж. Можна також зазначити роботу [14], яка базується на нелінійній структурі оцінки стану в реальному часі для відмовостійких додатків синхронізації інтелектуальної електромережі. Також була запропонована нелінійна авторегресійна модель прогнозування розподілу електроенергії [15]. З іншого боку, є пропозиція методу базової оцінки з використанням множинної лінійної регресії [16]. Проте в [17] представлено повне порівняння трьох моделей прогнозування, що використовують моделі на основі машинного навчання.

Машинне навчання також використовується для прогнозування та розподілу електроенергії в розумних мережах. Наприклад, пропонується

платформа керування великими даними для прогнозування навантаження в режимі реального часу, гібридна модель [18] прогнозування електричного навантаження на основі точної та швидкої конвергенції на основі ШНМ (AFC-ANN) і довгої короткочасної пам'яті (LSTM). Розроблено стратегію виявлення та класифікації багатьох несправностей на основі даних. Робота спрямована на виявлення та класифікацію численних несправностей. Також слід зазначити [19] засновану на глибокому навчанні модель діагностики несправностей. Робота використовує переваги RNN і LSTM, представляючи різні моделі глибокого навчання, включаючи CNN.

Отже, в існуючій літературі не вистачає обробки несправностей за допомогою стратегій автоматизації перерозподілу навантаження. Незважаючи на те, що більшість країн, що розвиваються, все ще використовують ручні методи перерозподілу навантаження, що займає значний час для виконання завдання оптимального перерозподілу навантаження, яке може тривати до кількох годин. Таким чином, новинкою в цьому дослідженні є використання добре відомих моделей машинного навчання для допомоги стратегіям автоматизації перерозподілу навантаження в країнах, що розвиваються. Оскільки ці країни мають дуже обмежені ресурси, включаючи погану інфраструктуру, а також зношену існуючу електромережу, існують різні проблеми для використання ручних методів перерозподілу навантаження, такі як час, зусилля та вартість.

### 1.3 Основи електроенергетичних систем

Електромережа – це складна система, що складається з мережі передачі електроенергії на великі відстані за допомогою високовольтних ліній електропередачі та розподільної мережі, яка доставляє електроенергію споживачам за допомогою низьковольтних ліній електропередачі. У традиційних енергетичних системах електроенергія тече в одному напрямку від централізованих великих синхронних генераторів до навантажень. Однак

зростання поширеності DER в сучасних системах розподілу електроенергії спричинило двонаправлені потоки електроенергії, що призвело до більшої кількості перенапруг, як показано на рисунку 1.2. Ці та інші проблеми, пов'язані з переходом на чисту енергію, створюють проблеми для експлуатаційної надійності електромереж.

Важливою вимогою для надійної та безпечної роботи електромережі є безперервне балансування попиту та пропозиції електроенергії, відмінності між якими проявляються у змінах частоти мережі (бажано постійні 60 або 50 Гц залежно від країни). Будь-який дисбаланс призводить до зміни частоти, яка падає від номінального значення у разі недостатньої генерації та збільшується при надлишку. Традиційно генерація та балансування навантаження досягалися шляхом планування (як частини проблеми зобов'язань одиниць) та диспетчеризації (як частини проблеми економічного диспетчеризації) контрольованого парку генеруючих потужностей, таких як електростанції, що працюють на вугіллі та природному газі, на один день вперед і змінюючи їх вихід у режимі реального часу відповідно до змінного навантаження (як частина автоматичного керування генерацією). Зобов'язання одиниць і економічна диспетчеризація включають модель витрат на виробництво, сформульовану як задачу програмування змішаних цілих чисел, яка мінімізує загальні експлуатаційні витрати масової енергосистеми, дотримуючись мережевих та інших фізичних обмежень. Навпаки, модель розширення потужності – також проблема оптимізації, але з іншими цілями – зосереджена на плануванні та політичних аспектах масових енергосистем. Так званий оптимальний потік потужності лежить в основі цих та інших проблем оптимізації та повсюдно поширений в енергосистемах.

Безпека постачання, яка має першочергове значення для надійної та безпечної роботи електромережі, стає все більш складною через високу частку змінної відновлюваної енергії [1]. Ці зміни вимагають нових послуг на всіх рівнях системи, від допоміжних послуг, що надаються відновлюваними джерелами енергії, до оптимальних ринкових рамок для отримання цих

послуг. Комунальні послуги з розподілу можуть задовольнити ці нові вимоги лише шляхом значного вдосконалення поточної практики роботи та планування, створюючи можливості для активного дослідження ML у різних контекстах системи розподілу, як показано на рисунку 1.2.

#### 1.4 Модель енергосистеми

Структуру електроенергетичної системи (відому як топологія) – що стосується фізичного розташування та з'єднання компонентів системи – можна концептуалізувати як граф, що складається з вузлів (шини), до яких під'єднані генератори та навантаження, і країв (ліній), які з'єднують ці вузли, як показано на рисунку 1.2. Залежно від проблеми, що розглядається, топологія енергетичної системи може бути представлена орієнтованим або неорієнтованим графом [20]. Це представлення полегшує математичне виведення моделі енергосистеми, яка використовується в усіх проблемах енергосистеми, від експлуатації та контролю до планування.

Загалом, модель енергосистеми містить набір рівнянь, що описують взаємозв'язки між змінними, що представляють інтерес, протягом досліджуваного періоду часу з урахуванням різних компонентів та їх більш-менш спрощених моделей, таких як трансформатори, автоматичні вимикачі, навантаження, лінії, і кабелі. Примітно, що модель розподільчої мережі відрізняється від моделі мережі передачі тим, що вона має:

- радіальну топологію або топологію мережі зі слабкою сіткою, яка часто змінюється;
- високе співвідношення опору до реактивного опору;
- незбалансовані фази через наявність багатьох асиметричних навантажень (однофазні та двофазні навантаження, переважно в Північній Америці).

Ці відмінності моделі мережі означають, що аналіз систем розподілу та передачі також відрізняється. Наприклад, прямим наслідком другої

відмінності є те, що опором лінії не можна нехтувати, спрощення, яке зазвичай використовується для аналізу традиційної системи передачі.

## 2 АНАЛІЗ ЕНЕРГОСИСТЕМИ ЯК ОБ'ЄКТА КЕРУВАННЯ

У цьому розділі представлено короткий огляд трьох фундаментальних проблем аналізу енергосистеми – проблеми потоку електроенергії, оптимального потоку електроенергії (OPF) і оцінки стану (SE) – з акцентом на проблеми, пов'язані з аналізом системи розподілу. Обговорюються проблеми в контексті додатків ML, тим самим слугуючи вступом до використання ML в аналізі енергосистем.

### 2.1 Проблема потоку електроенергії

Проблема потоку потужності, також відома як проблема потоку навантаження, є важливою для аналізу енергетичної системи в стаціонарному режимі. Це передбачає визначення стану системи за нормальних робочих умов, включаючи величини та кути напруги на всіх вузлах мережі [21] Після того, як стане відомо про стан системи, можна аналітично розрахувати будь-яку іншу важливу величину, таку як потік реальної та реактивної потужності та втрати на кожній лінії. Ця інформація має вирішальне значення для операторів енергосистем (надалі скорочено – оператори) для забезпечення надійної та безпечної роботи енергосистеми, оскільки вона дає їм змогу зрозуміти поведінку системи в різних умовах експлуатації, визначити потенційні проблеми та вжити коригувальних заходів для підтримки безпечної роботи умови. Як наслідок, аналіз потоків електроенергії є фундаментальним аспектом ключових операційних завдань енергосистеми, таких як OPF і SE, які будуть розглянуті нижче.

Проблема потоку потужності містить систему нелінійних рівнянь, представлених у полярній формі, як показано нижче:

$$\begin{aligned} P_i &= V_i \sum_{j \in N} V_j (G_{ij} \cos(\theta_i - \theta_j) + B_{ij} \sin(\theta_i - \theta_j)), \forall_i \in N, \\ Q_i &= V_i \sum_{j \in N} V_j (G_{ij} \sin(\theta_i - \theta_j) - B_{ij} \cos(\theta_i - \theta_j)), \forall_i \in N, \end{aligned} \quad (2.1)$$

де  $N$  – множина всіх шин у системі,  $P_i = P_i^G - P_i^L$  і  $Q_i = Q_i^G - Q_i^L$  – це чиста активна та реактивна потужності, що надходять на шину  $i$ , де верхні індекси  $G$  і  $L$  використовуються для позначення генерації та споживання потужності навантаження, відповідно.  $V_i$  та  $\theta_i$  представляють величину та фазовий кут напруги на шині  $i$ .  $G_{ij}$  та  $B_{ij}$  – це провідність і приймальна здатність лінії між шинами  $i$  і  $j$ , які відповідають дійсній і уявній частинам пропускної здатності лінії  $Y_{ij}$  відповідно. Поки (2.1) зазвичай використовується, важливо зазначити, що інші форми рівнянь потоку потужності (наприклад, прямокутна або векторна форма) можуть бути більш придатними для різних застосувань.

У більш загальній нотації рівняння потоку потужності можна виразити у формі короткого нелінійного алгебраїчного рівняння таким чином:

$$f(x, p, A) = 0, \quad (2.2)$$

де  $x$  – вектор системних невідомих,  $p$  – вектор параметрів лінії (наприклад, опорів і реактивних опорів), а  $A$  – матриця інцидентів, яка враховує топологію мережі. Вектор  $0$  представляє нульовий вектор. Оскільки замкнутого розв'язку для  $x$  не існує, система нелінійних рівнянь (2.2) зазвичай вирішується за допомогою ітераційних методів, таких як Ньютон-Рафсон або Гаусс-Зейдель [21].

Використовуючи наведене вище позначення, (2.1) можна записати компактно як

$$f(x) = \begin{bmatrix} \Delta P(x) \\ \Delta Q(x) \end{bmatrix} = 0. \quad (2.3)$$

Тут нелінійна функція  $f(\bullet)$  відображає комплексний вектор напруги  $x$ , що містить амплітуди напруги та фазові кути, на відповідні ін'єкції чистої потужності  $\Delta P, \Delta Q$ .

Примітка 1. У цьому документі модель енергосистеми зазвичай відноситься до формулювання алгебраїчної (статичної) моделі, подібної до (2.2), що є адекватним для опису стаціонарних або квазістаціонарних операцій. Формально така статична фізична модель може бути виражена за допомогою термінології ML як

$$y = Ax + \varepsilon, \quad (2.4)$$

де  $x$  і  $y$  – вхідний і вихідний вектори,  $\varepsilon$  відповідає помилці моделювання або шуму, а  $A$  – модельна матриця, яка може бути матрицею інцидентів із (2.2).

Коли ML застосовується до (2.4), як зображено на рисунку 1.1, отримується такий сурогат на основі даних, який часто називають «чорною скринькою»:

$$y = F(x) + \varepsilon. \quad (2.5)$$

Щоб уникнути фізичних невідповідностей або неправдоподібних результатів у результаті недосконалих даних або шумових вимірювань, які можуть негативно вплинути на продуктивність моделей ML, необхідно вийти за межі моделей, що керуються виключно даними, як-от (2.5) [22]. Саме тут моделі, засновані на фізиці (рисунок 1.1), вступають у гру і пропонують багатообіцяючий напрямок досліджень для продовження.

## 2.2 Оптимальний потік потужності

OPF регулярно використовується операторами для вирішення різних проблем енергосистеми, від планування до експлуатації. Загалом OPF формулюється як задача оптимізації з обмеженнями

$$\begin{aligned} \min_{x,u} \quad & c(x,u), \\ \text{s.t.} \quad & g_i(x,u) = 0 \quad (i=1,\dots,n), \\ & h_j(x,u) \leq 0 \quad (j=1,\dots,m), \end{aligned} \quad (2.6)$$

де  $c(\cdot)$  – цільова функція,  $x$  – вектор змінних рішень, що представляють стан системи, наприклад вихідні сигнали генератора, амплітуди та кути напруги,  $u$  – вектор змінних керування, що представляють керовані елементи системи, такі як задані значення генератора, а  $g(\cdot)$  і  $h(\cdot)$  є або лінійними, або нелінійними обмеженнями рівності та нерівності відповідно, що стосуються простору фізичних і робочих обмежень. Для ілюстрації, рівності відповідають рівнянням балансу потужностей  $2|N|$  (2.1), тоді як нерівності включають нижню та верхню межі критичних системних величин, таких як потоки в лініях, величини та кути напруги:

$$\begin{aligned} |S_{ij}|^2 &\leq (S_{ij}^{\max})^2, \quad \forall (i,j) \in L, \\ V_i^{\min} &\leq |V_i| \leq V_i^{\max}, \quad \forall i \in N, \\ \theta_i^{\min} &\leq \theta_i \leq \theta_i^{\max}, \quad \forall i \in N. \end{aligned}$$

Тут  $L$  – набір усіх ліній передачі в системі,  $S_{ij}$  та  $S_{ij}^{\max}$  – комплексний потік потужності та максимальний рейтинг для лінії  $(i, j)$ ,  $\theta_i$  – фазовий кут вектора напруги на шині  $i$ ,  $V_i^{\min}$  та  $V_i^{\max}$  є нижньою і верхньою межею величини напруги на шині  $i$  відповідно. Примітно, що мета OPF залежить від проблеми та може включати мінімізацію витрат, максимізацію стабільності

системи, максимізацію використання відновлюваних джерел енергії тощо. Це остаточно визначається  $s(\cdot)$  в (2.6).

Зауваження 2. Проблема OPF є нелінійною, невиключною та, як правило, великомасштабною (із залученими десятків тисяч змінних), що робить її складною для вирішення у недетермінований поліноміальний час (NP-). [23] Як наслідок, прийнято використовувати менш дорогі підходи до вирішення цієї проблеми, включаючи, такі, що перелічені нижче.

Лінійні апроксимації. Цей набір підходів до вирішення є обчислювально ефективним; однак це дає менш точні, неоптимальні рішення, які можуть порушувати операційні обмеження.

Опуклі релаксації. Хоча обчислювально більш інтенсивні, ніж попередні методи вирішення, головною перевагою підходів опуклої релаксації є збіжність до глобального оптимуму та гарантії здійсненності.

Чорна скринька або гібридні розв'язувачі. Цей набір підходів до рішень базується на ML, може бути непомірним для даних і зазвичай не надає гарантій оптимальності. У цій групі можна розрізнити наскрізне навчання, яке є найпопулярнішим у літературі про PES, і підходи навчання для оптимізації в OPF [24]. Наскрізнний підхід до навчання використовує контрольоване навчання для відображення вхідних даних, таких як вузлові введення чистої потужності, в оптимальне рішення, таке як напруга або генерація електроенергії, що призводить до високоякісних проксі оптимізації для рішень OPF. І навпаки, останній підхід використовує методи ML для прискорення швидкості обчислень існуючих алгоритмів оптимізації, які використовуються для вирішення OPF; одним із таких прикладів є використання ML для полегшення гарячого запуску вирішувачів OPF [24]. Таким чином, деякі з підходів навчання для оптимізації для OPF можна розділити на моделі ML на основі фізики, які також відомі як гібридні розв'язувачі.

Для детального огляду апроксимацій та послаблень рівнянь потоку потужності в контексті OPF, зокрема для перших двох підходів до

вирішення, перерахованих вище, може звернутися до різних джерел [24, 25].

Технології OPF ефективно використовувалися для оптимізації основних операцій енергосистеми, наприклад економічного розподілу генеруючого парку. Однак, застосування тих самих методів OPF до систем розподілу є складним через відмінності, описані вище. Більше того, дедалі більша присутність DER у сучасних системах розподілу посилює невизначеність, роблячи OPF (D-OPF) ще більш складним. Як результат, операторам потрібні рішення D-OPF, які можна виконувати майже в реальному часі, щоб точно відображати умови роботи системи та приймати своєчасні рішення в умовах невизначеності.

Незважаючи на значну кількість опублікованих робіт з проблеми D-OPF, вона залишається активною областю досліджень [25].

Нещодавня література надавала багато прикладів ML, які застосовувалися безпосередньо до OPF/D-OPF або їх варіантів, включаючи OPF з обмеженнями безпеки та ймовірнісні OPF, які враховують фактори невизначеності. Для короткого огляду використання ML в OPF можна звернутися до [26]. Одним із захоплюючих і багатообіцяючих напрямів досліджень є нейронні мережі, засновані на фізиці, для розв'язання OPF, одночасно накладаючи обмеження на функції оптимізації нейронної мережі. [27, 28].

### 2.3 Оцінка стану

SE є критично важливим завданням логічного висновку для забезпечення загальносистемної ситуаційної обізнаності шляхом визначення найбільш вірогідного робочого стану енергосистеми, зазвичай представленого складними векторами напруги, що містять величини напруги та фазові кути. Щоб досягти цього, SE вимагає двох ключових вхідних даних:

- доступні телеметричні дані в достатній кількості, щоб зробити

мережу доступною для спостереження;

- оновлена модель мережі, яка включає параметри та топологію мережі.

Основна мета SE полягає в тому, щоб забезпечити точну оцінку в реальному часі стану системи (позначеного  $x$ ), яка узгоджується з доступними вимірюваннями, насамперед величинами струму та напруги в розподільчих системах. Зокрема, вектор вимірювання  $z$  можна представити як  $z=h(x)+e$ , де  $e$  позначає похибку вимірювання. Нелінійна функція  $h(\cdot)$  пов'язує стан системи з цими вимірюваннями за допомогою попередньо визначених (обернених) рівнянь потоку потужності.

У класичному формулюванні набір вимірювань ( $z$ ) подається в оцінювач стану, який створює оцінки стану в усіх вузлах ( $x$ ) шляхом мінімізації залишків усіх вимірювань наступним чином:

$$\hat{x}(z) = \arg \min_x \|z - h(x)\|^2. \quad (2.7)$$

Зауваження 3. Надлишковість вимірювань і точне знання моделі мережі є передумовами для класичної системи SE, такої як зважені найменші квадрати (WLS). Оцінювач стану WLS десятиліттями використовувався в системах передачі; однак він не підходить для систем розподілу, де проблема SE залишається невизначеною через низьку спостережуваність мережі, як обговорюється нижче. Крім того, навіть якщо мережу можна спостерігати, оцінка стану WLS або подібні формулювання не можуть гарантувати рішення в усіх випадках і можуть зіткнутися з проблемами конвергенції, особливо для великомасштабних систем. Крім того, ці оцінювачі стану чутливі до помилок вимірювань і невірних даних [29].

Безпосереднє застосування класичної структури SE в системах розподілу є серйозною проблемою з трьох причин:

- низька спостережуваність через дефіцит вимірювальних приладів та

недостатню комунікаційну інфраструктуру;

- погані моделі мережі внаслідок невизначеності моделі мережі, тобто неточні параметри мережі та неповна інформація про топологію;
- незбалансовані операції.

Зараз оцінювачі стану розподілу покладаються на так звані псевдовимірювання [30] через труднощі вирішення першого та другого питань без суттєвих модернізацій існуючої інфраструктури зв'язку та вимірювання. Нажаль, така модернізація інфраструктури є економічно недоцільною через величезний масштаб систем розподілу.

З іншого боку, отримані від навантаження псевдовимірювання, які використовуються для компенсації недостатніх телеметричних даних, можуть поширювати значні помилки через оцінювач стану розподілу, що призводить до їх ненадійної роботи. Крім того, третє питання робить відокремлені версії оцінок стану, які використовуються в мережах передачі, непридатними для систем розподілу, що вимагає розробки трифазних оцінок стану. Отже, зростає інтерес до вивчення методів, які дозволяють точно оцінювати стан системи розподілу (DSSE), незважаючи на обмежені вимірювання та невизначеності в моделях системи. Серед цих методів дослідники зосередилися на ML і підходи до DSSE на основі розрідженості, які пояснюються нижче.

Застосунки ML. Методи ML показали багатообіцяючу продуктивність у різних аспектах, прямо чи опосередковано пов'язаних із SE, наприклад, виявлення поганих даних, ідентифікація топології, включаючи відображення трансформатора та клієнта та ідентифікацію з'єднання фаз, а також генерація та моделювання більш точних псевдовимірювань. Крім того, було запропоновано численні оцінювачі стану на основі ML, які можна загалом класифікувати на дві різні категорії, залежно від того, чи вимагають вони складних на практиці знань про модель розподільчої мережі (доповнена моделлю) чи ні (модельно-діагностична чи безмодельна). Примітно, що багато оцінювачів стану на основі ML, запропонованих у літературі,

передбачають рівень спостережуваності, що перевищує той, який зазвичай спостерігається в системах розподілу в реальному світі, або використовують стратегії оптимізації розміщення датчиків. Тому є численні можливості для подальших досліджень у цій галузі.

І останнє, але не менш важливе, варто виділити конкретну методологічну концепцію, що використовується в області рекомендаційних систем, яка має відношення до досліджень в енергосистемі SE [31]. Хоча системи рекомендацій зазвичай пов'язані з такими платформами, як Netflix, YouTube і Amazon, де ML використовується, щоб пропонувати предмети, які потенційно можуть бути цікавими для окремих користувачів, на основі даних інших користувачів, математичні концепції, що лежать в основі цих систем, також можна застосувати в потужності системний домен. Зокрема, завершення матриці низького рангу використовувалося в області DSSE, особливо в контексті мереж розподілу з низьким рівнем спостережуваності. В окремих інформаційних джерелах [32, 33] надаються приклади модельно-доповненого та безмодельного підходів до оцінки напруги, відповідно. Окрім методів завершення матриці, у сфері DSSE на основі розрідженості проводилися активні дослідження інших відповідних методів, таких як тензорне завершення [34].

#### 2.4 Загальні міркування щодо ML для аналізу системи розподілу електроенергії

В аналізі системи розподілу електроенергії високоточне моделювання має важливе значення для отримання надійних результатів. Традиційне моделювання системи розподілу електроенергії базується на складних фізичних моделях і суворих математичних принципах. Однак ці моделі можуть призвести до складних проблем оптимізації та моделювання, враховуючи великий масштаб цих систем. Щоб вирішити проблему масштабованості, моделювання системи розподілу електроенергії часто

спрощується за допомогою припущень і наближень, які мають багато форм, як-от лінеаризація або опукла релаксація. Такі спрощені моделі можуть бути задовільними для більшості робочих точок, але можуть призвести до неоптимальних рішень для інших. Це стає більш вираженим із збільшенням мінливості та невизначеності в умовах роботи системи через збільшення інтеграції DER.

Існує багато прикладів, коли ML може запропонувати ефективну альтернативу звичайним спрощенням, особливо там, де першочерговим завданням є отримання своєчасних рішень з урахуванням точності рішень. Одним із таких прикладів є використання ML для розробки сурогатних моделей – високоточних, обчислювально дешевих наближень детальної аналітичної моделі – для прискорення аналізу. Приклади можуть включати опуклі та неопуклі задачі оптимізації (наприклад, D-OPF, DSSE), моделювання Монте-Карло та апроксимацію нелінійних рівнянь потоку потужності, вбудованих у задачі на основі оптимізації.

Обчислювально інтенсивне моделювання Монте-Карло традиційно використовується для створення сотень і тисяч сценаріїв, що стосуються різних умов роботи системи (тобто, генерування електроенергії, споживання та рівня напруги) для різних відповідних досліджень, таких як оцінка безпеки за різних рівнів проникнення DER. Визначити найбільш критичний сценарій (тобто робочу точку) дуже складно, оскільки простір стану системи може бути величезним. З цією метою можна використовувати методи ML для оптимального пошуку в просторі станів, таким чином обходячи потребу виконувати аналіз потоку розподільної потужності для кожного сценарію окремо.

Зменшуючи часові навантаження на різні аналізи, ML може забезпечити більш комплексну та/або частішу оптимізацію, таким чином підвищуючи ефективність і надійність системи. Крім того, оскільки розв'язання моделей, що займає багато часу, часто обмежує вищезазначені проблеми офлайн-додатками, методи ML є перспективними інструментами

для перенесення розв'язання моделі з офлайн на онлайн-налаштування, які більше підходять для робочих умов, що змінюються в часі. Важливо зазначити, що в разі заміни оригінального детального аналізу на основі фізики сурогатами ML можуть бути втрачені певні гарантії щодо продуктивності, що обмежить застосування ML до додатків з великою шкодою, особливо в контексті стабільності системи.

## 2.5 Дані системи розподілу електроенергії

Цей розділ завершується оглядом різних типів джерел даних, що використовуються в системах розподілу електроенергії, і коротким обговоренням важливих міркувань, про які слід пам'ятати під час роботи з цими даними. Як зображено на рисунку 2.1, різноманітні джерела даних, такі як диспетчерське керування та збір даних (SCADA), метеостанції, метеорологічні бази даних і вимірювальні пристрої, включаючи 1-фазорні вимірювальні одиниці (1-PMU) і інтелектуальні лічильники, можна використовувати для різних програм ML. Однак важливо зазначити, що ці дані супроводжуються унікальними проблемами, такими як асинхронні вимірювання та обмежений доступ до вимірювань у реальному світі.

Неузгодженість у часовій роздільній здатності вимірювань розподілу виникає через просторово-часову неоднорідність датчиків, встановлених по всій мережі розподілу електроенергії, таких як розумні лічильники, 1-PMU та монітори польового обладнання. Ці датчики мають різну частоту дискретизації та час звітування, як показано на рисунку 2.2, що призводить до вимірювань різної часової роздільної здатності. Щоб ефективно використовувати ці вимірювання в системах ML, необхідно стандартизувати їх роздільну здатність. Для цього потрібно знизити частоту дискретизації даних із вищою роздільною здатністю, щоб відповідати даним з нижчою роздільною здатністю або навпаки (так зване підвищення дискретизації). Це можна зробити багатьма способами, від тривіальних методів лінійної

інтерполяції до більш просунутих методів ML; можна посилатися на останні роботи, де профілі навантаження з низькою роздільною здатністю підвищуються у профілі навантаження з високою роздільною здатністю за допомогою генеративних змагальних мереж (GAN).

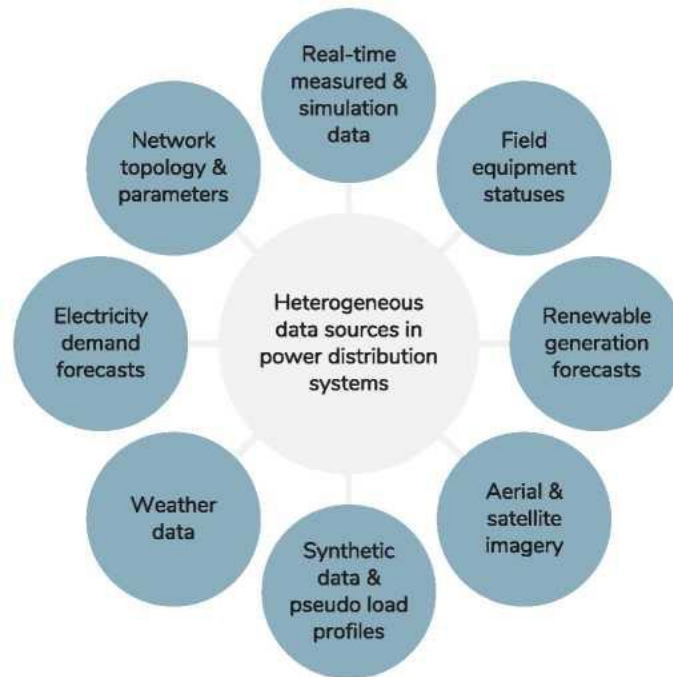


Рисунок 2.1 – Гетерогенні джерела даних у системах розподілу електроенергії

Іншим важливим фактором є обмежена доступність вимірних даних з реальних систем через відсутність датчиків на додаток до проблем конфіденційності та безпеки. З цих причин дослідники часто обмежуються використанням змодельованих і відкритих даних для розробки систем машинного навчання. Однак моделювання зазвичай передбачає безпомилкові вимірювання та відсутність затримок зв'язку, що нереально для вимірювань у реальному світі. Щоб вирішити цю проблему, дослідники можуть вводити шум, який слідує за певними припущеними розподілами, які можуть неточно відображати моделі шуму, виявлені в фактичних вимірюваннях. Крім того, набори даних із відкритим вихідним кодом могли пройти попередню обробку

та не мати певних функцій, які могли б мати відношення до досліджуваної проблеми.

## 3 ПІДХОДИ ДО ВИКОРИСТАННЯ ML

Цей розділ слугує коротким вступом до сфери машинного навчання. Він заглиблюється в фундаментальні принципи машинного навчання та класифікує різні парадигми навчання. Подаючи приклади з точки зору систем розподілу, він ілюструє обговорювані концепції та служить відправною точкою для аналізу потенціалу машинного навчання в галузі енергетики.

### 3.1 Основи навчання

Навчальне завдання  $T$  можна описати як процес оптимізації показника ефективності  $L$  на основі досвіду навчання  $D$  [35]. Це завдання зазвичай включає три основні компоненти:

- вхідні дані (також відомі як навчальний набір або набір функцій);
- модель (або алгоритм);
- вихідні дані або прогноз (також відомий як мітка або ціль).

Щоб спростити обговорення, далі формально визначимо навчальне завдання, припускаючи налаштування навчання під наглядом, яке більш детально розглядається окремо. Цей тип навчання не тільки широко вивчався в галузі PES, але він також забезпечує міцну основу для пояснення фундаментальних концепцій ML.

Для початку слід коротко застосувати наведену вище абстрактну термінологію машинного навчання до конкретного прикладу в контексті систем розподілу. В енергетичних системах мікромережа визначається як невелика електрична мережа, яка може працювати або підключеною до великої мережі, або в автономному режимі. Розглянемо приклад формування мікромережі для сприяння відновленню розподільчої мережі під час подій із низькою ймовірністю та сильним впливом, таких як екстремальні погодні явища. Навчальна задача в цьому сценарії може бути сформульована як

сегментація розподільчої мережі на автономні (мікромережеві) зони. Мірою продуктивності, яку необхідно покращити в такому навчальному завданні, може бути мінімальний час, необхідний для відновлення розподільчої мережі, або, альтернативно, кількість критичних споживачів, які стикаються з перебоями в електропостачанні. Досвід навчання може передбачати попереднє визначення всіх можливих мікросіток у спостережуваній мережі.

За більш формальним визначенням навчальну задачу  $T$  можна описати як побудову відображення  $f: X \rightarrow Y$ , використовуючи навчальні дані  $D = \left\{ \left( x^{(i)}, y^{(i)} \right) \right\}_{i=1}^m$ , щоб знайти функцію прогнозування  $h \in H$ , таку, що для невидимої входної пари  $(x^*, y^*)$ ,  $h(x^*)$  є хороша модель; тут  $m$  – кількість навчальних вибірок,  $X$  і  $Y$ , відповідно, позначають вхідний і вихідний простір, а  $H$  – простір гіпотез моделей-кандидатів. У деяких випадках функція  $h(\cdot)$  представлена явно як параметризована функціональна форма; в інших випадках функція неявна. В обох випадках функція зазвичай залежить від параметрів, а навчання відповідає пошуку значень для цих параметрів, які оптимізують показник  $L$  продуктивності [35]. Математично  $T$ , визначене вище, можна сформулювати як

$$h(x^*) = \arg \min_{f \in H} L + R, \quad (3.1)$$

де

$$L = \frac{1}{m} \sum_{i=1}^m l_1(f(x_i), y_i). \quad (3.2)$$

У (3.1)  $L$  є функцією втрат, яка використовується як критерій навчання для задачі оптимізації,  $R$  є необов'язковим терміном регуляризації, який використовується для зменшення ризику переобладнання.




Рисунок 3.1 – Діапазон часових дозволів вимірювань розподілу

Зауваження 4. Що означає хороша модель у наведеному вище визначенні? У сфері ML для PES термін «хороша модель» не має чіткого визначення та може тлумачитися. Загалом, хороша модель – це та, яка добре узагальнює дані, які раніше не бачили. Однак, коли справа доходить до PES, при визначенні хорошої моделі слід враховувати інші критерії. Наприклад, слід розглянути особливості моделі, яка усуває перешкоди для застосування в реальному світі. Тим не менш, відсутність чіткого консенсусу щодо того, що є хорошою моделлю в дослідженнях PES, може призвести до труднощів у практичному застосуванні методів ML у цій галузі. Тому дослідники повинні встановити чіткі стандарти та визначення для хороших моделей у PES, щоб зробити використання методів ML успішним у реальному світі. Розробка реалістичних контрольних задач може допомогти спільноті в цілому узгодити послідовне визначення хорошої моделі для кожного застосування ML до PES.

### 3.1.1 Функція втрат

Точність алгоритму ML визначається кількісно за допомогою функції втрат – математичної функції, яка вимірює різницю між прогнозованим результатом (також відомим як передбачення або оцінка), створеним алгоритмом ML, і фактичним результатом (також відомим як основна правда). Функція втрат оптимізується під час процесу навчання за допомогою таких методів, як градієнтний спуск, щоб підвищити

прогностичну ефективність моделі.

Визначення функції втрат залежить від конкретного навчального завдання. Для завдань регресії, де результатом є дійсне число ( $Y$ , вбудоване в набір  $R$ ), часто використовується квадратична функція втрат, яка визначається таким чином:

$$l(f(x), y) = (f(x) - y)^2. \quad (3.3)$$

Як альтернатива, можна використовувати функцію втрат абсолютного значення, яка визначається як

$$l(f(x), y) = |f(x) - y|. \quad (3.4)$$

Для завдань класифікації, де вихідні дані належать до кінцевого набору міток класів, функція втрат крос-ентропії є популярним вибором через її імовірнісну інтерпретацію. Ця функція втрат вимірює різницю між прогнозованим і справжнім розподілами ймовірностей і надається як

$$l(f(x), y) = -\sum_{k=1}^K y_k \log(f(x_k)), \quad (3.5)$$

де  $K$  – кількість класів,  $y_k$  – одноразово закодована основна мітка істинності для класу  $k$ , а  $f(x_k)$  – передбачена ймовірність належності вибірки до класу  $k$ .

Втрата нуль-один (втрата 0-1) часто використовується для завдань двійкової класифікації. Вона карає за неправильну класифікацію, присвоюючи значення 1, і нагороджує правильну класифікацію значенням 0, вираженим як

$$l(f(x), y) = \delta_{f(x) \neq y} \quad (3.6)$$

де

$$\delta_{f(x) \neq y} = \begin{cases} 1, & \text{if } f(x) \neq y, \\ 0, & \text{otherwise.} \end{cases} \quad (3.7)$$

Завдяки своїй недиференційованості втрата 0-1 зазвичай використовується як метрика оцінки, а не як функція втрат під час процесу навчання, на відміну від втрати крос-ентропії. Для отримання більш детальної інформації з всебічного огляду 31 функції втрат можна звернутися до [36].

### 3.1.2 Вимоги до даних

Як обговорювалося вище, завдання навчання залежить від досвіду навчання або, іншими словами, даних. Однак необроблені дані рідко використовуються в процесі навчання; вони часто потребують попередньої обробки та форматування. Ці кроки, як правило, підпадають під егіду розробки даних і є життєво важливими для розробки якісних систем машинного навчання.

Перший крок (попередня обробка даних) може включати деякі, якщо не всі, наступні підетапи:

- очищення даних, яке використовується для виявлення та виправлення або видалення пошкоджених спостережень – відсутні дані та викиди;

- вибір ознак, який передбачає вибір «оптимальної» підмножини незалежних змінних (ознак) з багатьох менш корисних; це означає ігнорування інших функцій як нерелевантних. Ці методи є інструментальними, коли є багато характеристик і порівняно мало даних

спостережень;

- масштабування ознак, яке передбачає нормалізацію діапазону ознак даних. Приклади включають нормалізацію середнього значення, нормалізацію мінімально-максимального значення та стандартизацію.

Другий крок (форматування даних) – переконатися, що вхідні дані правильно відформатовані. Найпоширенішим є табличний формат (так зване векторно-матричне представлення даних), де кожен рядок і стовпець таблиці представляють окремий приклад (також званий екземпляром) і ознаку (також звану коваріатом), відповідно. Розглянемо один розподільний фідер і відповідні минулі вимірювання на кожному вузлі як ілюстративний приклад того, як цю систему можна представити в табличній формі. У такій таблиці кожен рядок відповідає моменту часу, коли були зроблені знімки вимірювань, а стовпці відповідають різним виміряним змінним у кожному вузлі (наприклад, напруги, введена комплексна потужність, споживана комплексна потужність).

Зауваження 5. У контексті додатків ML у домені системи розподілу дані, які використовуються, переважно структуровані у табличному форматі. Однак існують певні винятки з цього, наприклад, супутникові зображення, які можна використовувати для оцінки позамірної сонячної генерації, або теплові зображення розподільних ліній і трансформаторів, які можна використовувати для прогнозного обслуговування.

### 3.1.3 Оцінка продуктивності моделі

Оцінка ефективності моделі ML має відбуватися на незалежному тестовому наборі даних. Загалом, повний набір даних складається з двох (навчання/випробування) або трьох (навчання/перевірка/тестування) окремих наборів:

- навчальний набір, як правило, найбільша вибірка даних, використовується для вивчення прогнозової моделі ML;

- набір перевірки – це менша вибірка даних, яка використовується для оцінки продуктивності моделі під час навчання та точного налаштування її гіперпараметрів, щоб запобігти надмірному або недостатньому підбору даних навчання;

- тестовий набір – це незалежний набір даних, який не використовується в процесі навчання чи налаштування гіперпараметрів. Замість цього він використовується для оцінки продуктивності прогновної моделі ML на нових, невідомих даних.

Ще один метод оцінки та вибору моделей ML – перехресна перевірка. У цьому підході дані поділяються на підвибірки, а рівень помилок оцінюється як середнє значення частот помилок, розрахованих на основі всіх підвбірок даних.

### 3.2 Таксономія парадигм навчання

Сфера ML охоплює різні парадигми навчання, включаючи контрольоване, неконтрольоване та навчання з підкріпленням. Ці парадигми були ретельно вивчені та широко прийняті в різних областях застосування [35]. Короткий виклад їхніх ключових характеристик і відповідних алгоритмів представлено на рисунку 3.2, закодовано кольором для того, щоб допомогти розрізнити їх, коли вони будуть обговорені окремо більш детально. Слід зосередитися на цих основних парадигмах навчання, включаючи напівкерване навчання (SSL). Для повного огляду останніх досягнень у цій галузі, включно навчання з передачею, багатозадачністю і багаторакурсне навчання можна звернутися до [37].

Серед різних парадигм ML варто відзначити різницю між офлайн-навчанням та онлайн-навчанням. Під час офлайн-навчання пакет зразків даних обробляється одночасно, тоді як під час онлайн-навчання зразки даних обробляються послідовно в міру надходження з часом. Хоча контрольовані та неконтрольовані методи навчання можуть бути реалізовані за допомогою

стратегій навчання офлайн або онлайн, ці методи традиційно асоціюються з реалізацією офлайн. Навпаки, навчання з підкріпленням, яке спирається на послідовну взаємодію між агентом і середовищем, в основному працює онлайн. Тим не менш, існують також менш представлені форми навчання з підкріпленням, такі як пакетне навчання з підкріпленням, яке роз'єднує процеси збору даних і навчання політикам, таким чином оновлюючи політику агента пакетом попередньо зібраних даних. Іншою такою формою є чисте пакетне (або офлайн) навчання з підкріпленням, яке спрямоване на вивчення політики виключно з відповідним чином різноманітного та значного набору даних, позбавленого будь-якої онлайн-взаємодії.

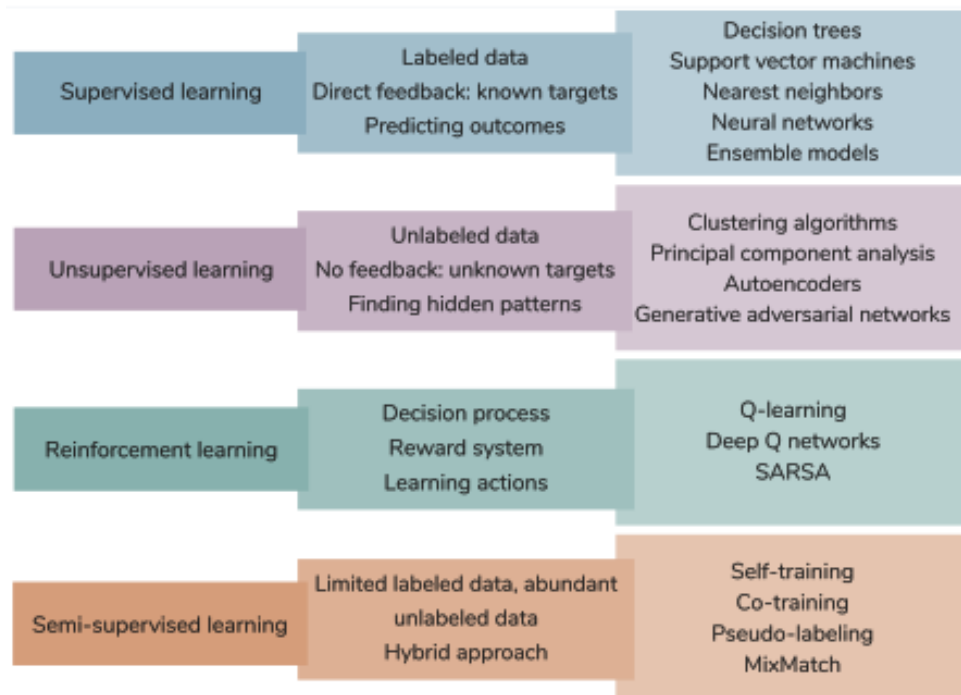


Рисунок 3.2 – Парадигми ML

Інша відмінність є між дискримінаційними та генеративними моделями. Дискримінаційні моделі вивчають умовний розподіл ймовірностей  $p(y|x)$ , тоді як генеративні моделі вивчають спільний розподіл ймовірностей  $p(x,y)$  [38]. Хоча дискримінаційні моделі в основному використовуються для класифікаційних завдань, їх також можна використовувати для інших типів

контрольованих навчальних завдань, таких як регресія та структуроване передбачення, де результатом є структурований об'єкт, такий як послідовність або дерево. З іншого боку, генеративні моделі в основному використовуються для неконтрольованих завдань навчання зі створення нових зразків даних, які нагадують навчальні дані. Генеративні моделі особливо багатообіцяючі для додатків, де навчальний набір даних невеликий або його важко отримати.

## 4 МОДЕЛЬ СИСТЕМИ РОЗПОДІЛУ ЕЛЕКТРОЕНЕРГІЇ

### 4.1 Базові відомості

Однією з головних особливостей інтелектуальної мережі є автоматизація розподілу електроенергії (DA), що означає автоматизацію роботи системи розподілу, наприклад функції SCADA [39], захист та аналогічні операції інформаційних технологій. Автоматизація розподілу може поєднувати дистанційне керування комутаційними пристроями, локальну автоматизацію та централізований процес прийняття рішень у гнучку, узгоджену та економічно ефективну операційну архітектуру для систем розподілу електроенергії, зберігаючи цілісність специфікації.

Однією з основних проблем, пов'язаних із відсутністю системи автоматизації розподілу в країнах, що розвиваються, є інвестиції у створення комунікаційної інфраструктури, віддалених терміналів (RTU) та встановлення датчиків. Країни, що розвиваються, мають багато чого зробити, щоб покращити інфраструктуру DA, оскільки це буде вигідно для зниження сукупних технічних і комерційних втрат та забезпечення кращої якості постачання.

Хмарні обчислення допомагають у розробці IoT у реальному світі. Але не кожна система IoT може мати переваги хмарних обчислень. Наприклад, промислові системи IoT потребують високошвидкісного керування таким чином, щоб дані, отримані від датчиків, могли миттєво оброблятися. Затримка, викликана хмарою в системі IoT, може завдати шкоди системам, які потребують миттєвої обробки потоку даних і негайного зворотного зв'язку. Тому з'явився новий обчислювальний підхід під назвою Fog computing [40]. Таким чином, він має суть хмарних обчислень на межі, але в той же час покладається на хмару для широкого рівня обробки історичних даних. Однак він утворює перехід між периферійними пристроями та

хмарою. Крім того, обчислення Fog отримали набагато більше покращень порівняно з хмарними обчисленнями, як-от менша затримка обробки, зменшена затримка та низька пропускну здатність [7].

Локалізація несправності відіграє важливу роль у забезпеченні надійності електропостачання. Велика дослідницька робота, пов'язана з алгоритмами визначення несправності, проводилася протягом багатьох років, однак точність і швидкість є основними проблемами [41].

Крім того, доступні дані в реальному часі в базах даних SCADA містять інформацію про умови експлуатації, яка є корисною для оптимізації обслуговування підстанції. Таким чином, несправності та збої підстанцій контролюються через систему SCADA. Отже, аналіз цих даних корисний для оцінки стратегії технічного обслуговування та планування реконструкції та заміни обладнання.

Крім того, великі дані стають все більш вимогливими та критичними. Нагляд і ручне прийняття рішень щодо появи цих даних також стає важчим. Тим не менш, використання системи SCADA є більш складним, оскільки рішення має прийматися в режимі реального часу. Одним із спонукальних рішень для вирішення таких проблем є використання штучного інтелекту або машинного навчання, оскільки він зменшує ручну взаємодію.

Також, для автоматизації розподілу електроенергії з'явився механізм інтеграції, який інтегрує Fog Router і Cloud із системою на основі IoT SCADA. Кожен територіальний маршрутизатор призначений для певного регіону, він зв'язується з датчиками та контролерами в цьому регіоні та інтелектуально реагує на несправності та критичні проблеми розподілу. Крім того, він може спілкуватися з іншими маршрутизаторами на основі попередньо визначеного протоколу [8].

У цій роботі пропонується метод обробки несправностей у розумних мережах, щоб мінімізувати тривалість несправності, особливо в країнах, що розвиваються, де раніше майже не докладалося жодних зусиль. Пропонований метод базується на машинному навчанні, тому внесок у цю

роботу полягає в тому, щоб змусити мережу перерозподіляти навантаження на основі різних підходів машинного навчання. Тому було побудовано різні моделі, модель множинної лінійної регресії, модель нелінійної регресії та модель нейронної мережі.

## 4.2 Модель системи

Для моделювання інтелектуальної мережі можна використовувати різні методи моделювання. У цій роботі використані три добре відомі моделі, засновані на машинному навчанні, які застосовуються для перевірки достовірності припущення про автоматизацію перерозподілу навантаження, де моделями є:

- множинна лінійна регресія;
- нелінійна регресія;
- модель класифікатора нейронної мережі.

Кожна модель застосовується окремо для впорядкування пріоритетів резервних трансформаторів, які можуть впоратися з несправним навантаженням трансформатора на основі трьох вхідних змінних, якими є:

- вільне навантаження кожного трансформатора;
- температура масла;
- очікувана втрата потужності між трансформаторами.

У цьому дослідженні застосовано моделі на основі регресії через простоту регресії та тому, що їх обчислення можна легко виконати за допомогою ресурсів обробки, доступних у контролерах. Тому для множинного лінійного та нелінійного регресійного моделювання використано інструменти MATLAB `fitlm` та `fitnlm` відповідно. Для створення моделі класифікатора нейронної мережі використано бібліотеку Python `Keras`.

### 4.3 Архітектура системи

Архітектуру електричної мережі в цій роботі можна описати як інтелектуальну мережу, де мережа логічно розділена на різні зони, де кожна зона має кілька трансформаторів і контролер, який контролює розподіл навантаження між зонними трансформаторами. Таким чином, кожен контролер оснащений приводами на основі IoT.

Як показано на рисунку 4.1, кожен трансформатор оснащено вимірювальними датчиками на основі IoT, які вимірюють величину струмового навантаження та температуру масла. Тоді як втрати потужності між кожною парою трансформаторів оцінюються за допомогою хмарної централізованої системи знань SCADA. Трансформатори в кожній зоні можуть працювати у відмовостійкому механізмі, який може впоратися з навантаженням несправного трансформатора. Іншими словами, коли в одному трансформаторі виникає несправність, контролер зони вибере найбільш відповідний трансформатор на основі підходу машинного навчання SCADA.

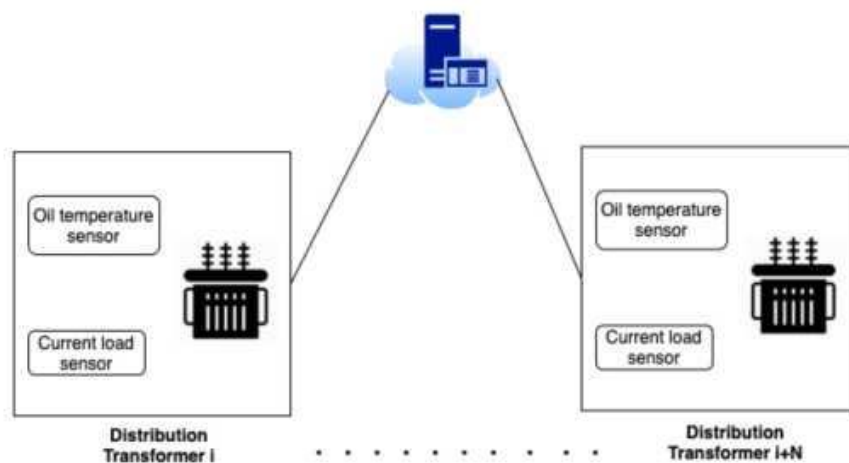


Рисунок 4.1 – Архітектура системи різних зон

Таблиця 4.1 – Таблиця пріоритетів

Розподільний трансформатор/ резервний трансформатор	СТ1	СТ2	СТ3	СТn
S1	X	P12	P13	P1n
S2	P21	X	P23	P2n
S3	P31	P32	X	P3n
Sn	Pn1	Pn2	Pn3	X

#### 4.4 Компоненти системи

Рисунок 4.2 надає загальний ескіз, який найкраще описує інтелектуальну мережу, що використовується в даній роботі. Таким чином, датчики на кожному трансформаторі періодично надсилають оновлення до хмарної аналітичної системи, яка, у свою чергу, контролює механізм розподілу навантаження через актуатори IoT. Отже, коли в розподільчому трансформаторі виявляється несправність, контролер розподіляє навантаження на найбільш відповідний трансформатор згідно з критерієм пріоритетності, де критерій пріоритетності можна описати наступним чином.

Найвищий пріоритет має трансформатор-кандидат (СТ), який має найвище вільне навантаження, найнижчу температуру масла та найменшу розрахункову втрату енергії у відсотках. Отже, трансформатори сортуються на багаторівневному рівні відповідно до:

- значення вільного навантаження: від найбільшого до найменшого;
- значення температури масла: від найнижчої до найвищої;
- розрахункова втрата енергії у відсотках: від найменшого до найвищого.

Як показано в таблиці 4.1, система має таблицю прогнозів, яка містить N рядків і N стовпців. Кожен рядок містить пріоритети N-1 трансформаторів-кандидатів (СТ), упорядкованих від найвищого до найнижчого, при цьому

діагональний елемент нехтується. Тому, коли  $k$ -й трансформатор виходить з ладу, це обробляється  $i$ -м трансформатором струму в  $K$ -му рядку, який має максимальне значення пріоритету ( $P_{ki}$ ). Таблиця прогнозів періодично оновлюється на основі алгоритму, наведеного на рисунку 4.3.

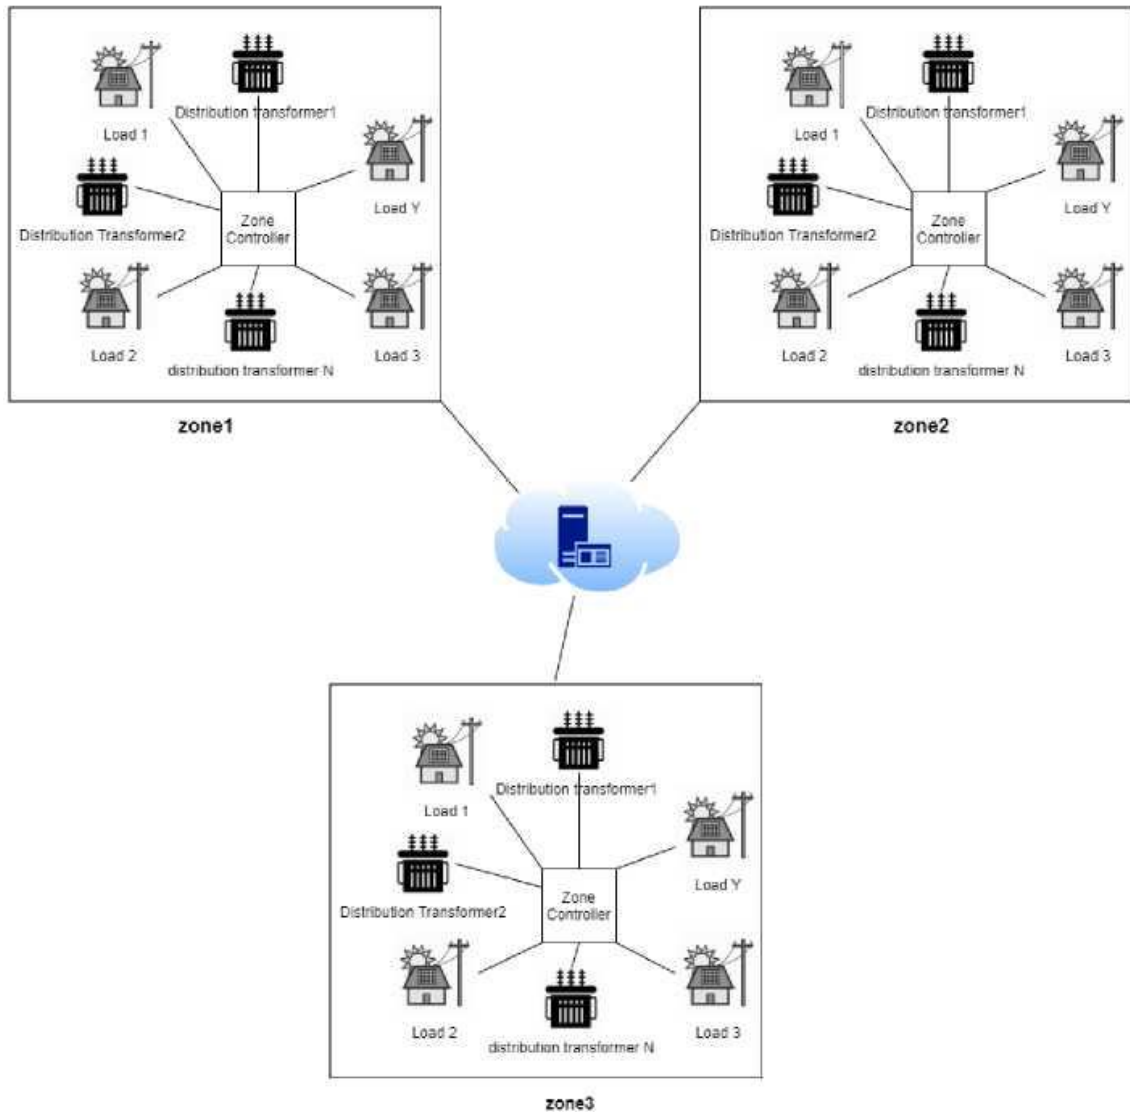


Рисунок 4.2 – Періодичні оновлення, які надсилає датчик на кожному трансформаторі

## 4.5 Методологія

У цьому дослідженні припущено, що інтелектуальна мережа заснована на SCADA, тобто показання датчиків збираються та контролюються через централізовану хмарну систему. Новизна цієї роботи полягає у введенні трьох моделей машинного навчання для відмовостійкого механізму перерозподілу навантаження, який інтегрований з інтелектуальною мережею на основі SCADA. Як було зазначено вище, кожна модель із трьох була досліджена окремо, де експериментальні етапи можна описати наступним чином.

1. Частина збору даних була виконана таким чином:

- для множинної лінійної регресії та моделей на основі нелінійної регресії були зібрані випадкові показання для певної зони від Північної електророзподільної компанії (NEDCO), щоб побачити рівень точності побудови миттєвої моделі, яку можна періодично адаптувати протягом коротких періодів часу;

- для моделі нейронної мережі показання збиралися від однієї компанії для тієї самої зони кожні шість годин протягом одного місяця.

2. Частина оцінки та перевірки моделей, згадана раніше:

- множинна лінійна регресія та моделі на основі нелінійної регресії були оцінені та перевірені за допомогою інструментів MATLAB fitlm та fitnlm відповідно.

- модель нейронної мережі оцінюється та перевіряється бібліотекою Python Keras.

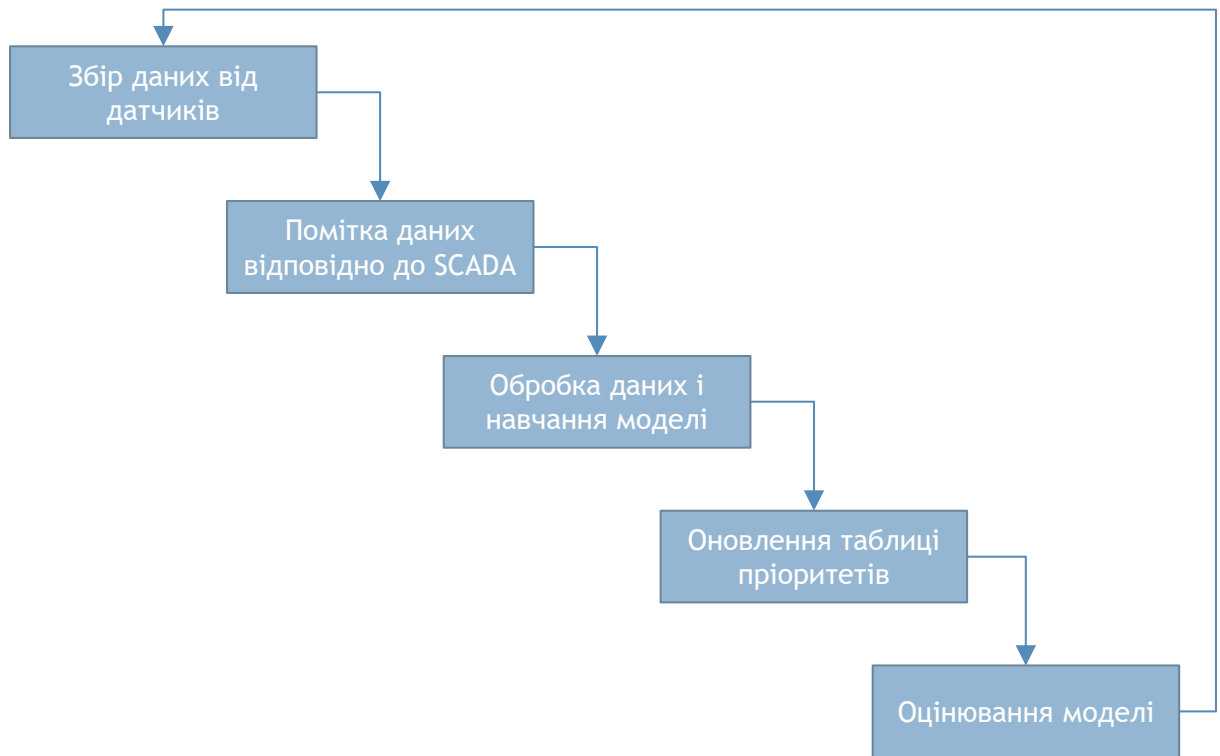


Рисунок 4.3 – Алгоритм оновлення таблиці пріоритетів

Таким чином, у цих моделях використовуються такі позначення:

$P_{ki}$  – 1-й пріоритет трансформатора, який може витримати навантаження  $k$ -го трансформатора.

$C_i$  – вільна ємність 1-го трансформатора; тобто скільки навантаження в кВА може витримати СТ<sub>*i*</sub> на додаток до поточного навантаження.

$T_i$  – температура масла СТ<sub>*i*</sub>.

$L_i$ : відсоток втрат енергії під час передачі енергії по лініях між  $k$ -м трансформатором і СТ<sub>*i*</sub>.

Оскільки значення  $P_{ki}$  пропорційне  $C_i$  та обернено пропорційне як  $T_i$ , так і  $L_i$ , запропонована модель

$$P_{ki} = \frac{C_i^X}{T_i^Y * L_i^Z} \quad (4.1)$$

де: X, Y і Z – параметри регресійної моделі.

Таким чином, ці значення можна знайти різними методами та інструментами, як пояснюється нижче.

1. Модель на основі множинної лінійної регресії: як показано в рівнянні (4.2), вивчалось співвідношення між натуральними логарифмами  $P_{ki}$  та  $C_i$ ,  $T_i$  та  $L_i$ . Значення  $X$ ,  $Y$  і  $Z$  можна знайти за допомогою кількох методів лінійної регресії, де ми використовували інструмент MATLAB `fitlm`

$$I_n(P_{ki}) = X \ln(C_i) + Y \ln(T_i) + Z \ln(L_i) + W \quad (4.2)$$

де  $W$  – точка перетину

2. Нелінійне моделювання: у цій частині використовувалися ті самі дані та інструмент Matlab `fitnlm`, щоб знайти параметри  $X$ ,  $Y$  і  $Z$ .

3. Підхід нейронних мереж: щоб мати справу з високодинамічним середовищем, необхідно розглянути підхід, який базується на нейронних мережах. Таким чином, система є самонавчальною, тобто вона може адаптуватися до різної кількості трансформаторів. У цій частині було використано бібліотеку Python Keras для побудови нейронної мережі, яка змусить систему вибрати найбільш придатний трансформатор-кандидат. Класи-оболонки, надані бібліотекою Keras, дозволяють використовувати моделі нейронних мереж, розроблені за допомогою Keras, у scikit-learn. Крім того, у Keras є клас KerasClassifier, який можна використовувати як оцінювач у scikit-learn [42]. KerasClassifier приймає назву функції як аргумент. Ця функція повинна повертати сконструйовану модель нейронної мережі, готову до навчання.

У даному випадку функція створює базову нейронну мережу для проблеми класифікації пріоритетів. Створюється проста повністю пов'язана мережа з одним прихованим шаром, який містить 45 нейронів. Прихований рівень використовує функцію активації випрямляча, що є хорошою практикою, де вихідний рівень створює 20 вихідних значень, по одному для кожного класу. Слід звернути увагу, що використовувалася функція активації

«softmax» у вихідному рівні [43]. Це робиться для того, щоб вихідні значення були в діапазоні від 0 до 1 і могли використовуватися як прогнозовані ймовірності. Нарешті, мережа використовує ефективний алгоритм оптимізації градієнтного спуску Адама з логарифмічною функцією втрат, яка в Keras називається «categorical\_crossentropy».

Таблиця 4.2 – Результати використання fitlm для (4.2)

Ім'я	Значення
W	-2,2957
X	1,0647
Y	-0,0039374
Z	-0,052378

#### 4.6 Результати

Домінуючим обмеженням у цьому дослідженні є кількість розподільних трансформаторів у зоні. Згідно з NEDCO, трансформатори згруповані в зони на основі географічних і топологічних міркувань. А оскільки географічний простір невеликих країн обмежений, то кожна зона містить майже 20 розподільних трансформаторів. Таким чином, надана зона від NEDCO для розгляду в цій роботі містить 20 розподільних трансформаторів. Отже, кожному трансформатору присвоюється значення пріоритету відповідно до його здатності працювати як резервний трансформатор, де значення пріоритету варіюються від 1 до 20. Пріоритет 20 у розподільного трансформатора означає, що цей трансформатор слід вважати першим для роботи як резервний трансформатор. З іншого боку, якщо трансформатор має значення пріоритету 1, то він повинен бути останнім, який вважається резервним трансформатором.

Після машинного навчання на основі заданого припущення модель було верифіковано. Експеримент проводився на машині, яка складається з

процесора IntelR Core™ i7-7700HQ на 2,80 ГГц і 16 ГБ оперативної пам'яті. Модель класифікатора реалізовано за допомогою python 3.8, оскільки він вважається однією з найкращих платформ машинного навчання через його простоту, гнучкість і послідовність величезних бібліотек для штучного інтелекту та машинного навчання. Модель Classifier була побудована з використанням різних інструментів глибокого навчання, таких як Numpy, Tensorflow, Keras, Pandas, Matplotlib і PyLab. Множинні моделі лінійної та нелінійної регресії були створені за допомогою MATLAB R2016b.

#### 4.6.1 Регресійні моделі MATLAB

На основі рівняння (4.2) було реалізовано множинну лінійну регресію за допомогою інструменту Matlab fitlm. Отже, отримані результати показані в таблиці 4.2, де кількість спостережень дорівнює 20, а похибка ступенів свободи дорівнює 16.

Рисунок 4.4 показує порівняння між обчисленими значеннями  $R_{ki}$  з використанням цих коефіцієнтів і значеннями навчання.

На основі рівняння (4.1) реалізовано нелінійну регресію за допомогою інструменту Matlab fitnlm. Отримані значення коефіцієнтів  $X$ ,  $Y$  та  $Z$  наведені в таблиці 4.3. Кількість спостережень дорівнює 20, а похибка ступенів свободи дорівнює 17. Рисунок 4.5 демонструє порівняння обчислених значень  $R_{ki}$  з використанням цих коефіцієнтів і значень пріоритету навчання.

#### 4.6.2 Модель нейронної мережі Python

Щоб оцінити модель нейронної мережі за використаними навчальними даними, scikit-learn має чудові можливості для оцінки моделей за допомогою набору методів. Спочатку модель було оцінено за допомогою KerasClassifier і k-кратної перехресної влідації з використанням показників точності в якості

індикатора продуктивності зі значенням  $\text{epochs} = 100$  і  $\text{batch\_size} = 5$ . Рисунок 4.6 показує залежність точності від  $k$ . Середнє значення точності становить 96,58%, де стандартне відхилення становить 2,3%.

Крім того, було використано функцію відповідності з  $\text{validation\_split} = 0,33$ ,  $\text{epochs} = 150$  і  $\text{batch\_size} = 50$  для порівняння кривої точності навчання з кривою точності тестування, а також для порівняння кривих втрат під час навчання та втрат при тестуванні. Крім того, модель була повторно оцінена з використанням середньої абсолютної помилки (MAE). Середнє значення MAE становить 0,083, і рисунок 4.7 показує залежність MAE від кількості епох.

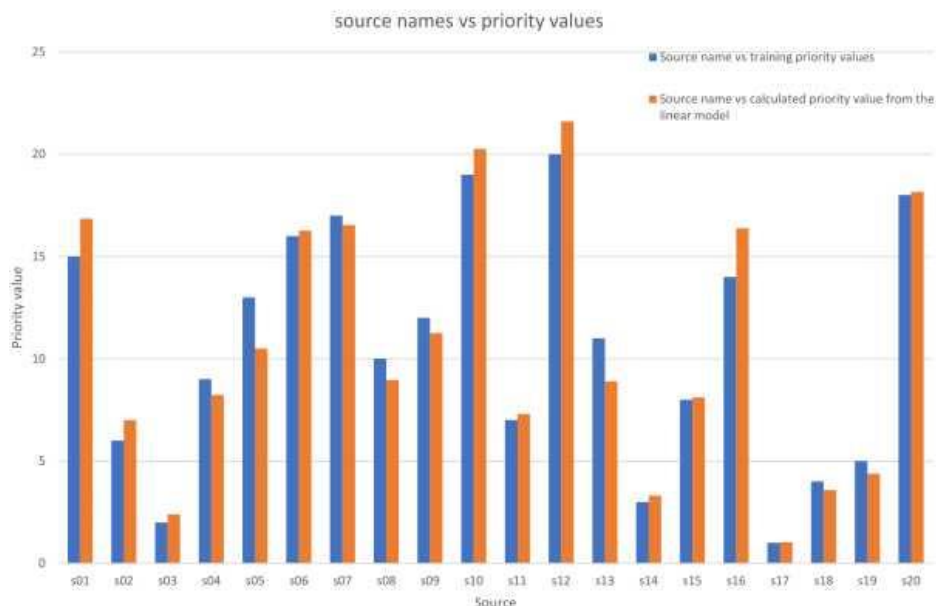


Рисунок 4.4 – Порівняння значень пріоритету, отриманих в результаті навчання та розрахованих за множинною лінійною моделлю

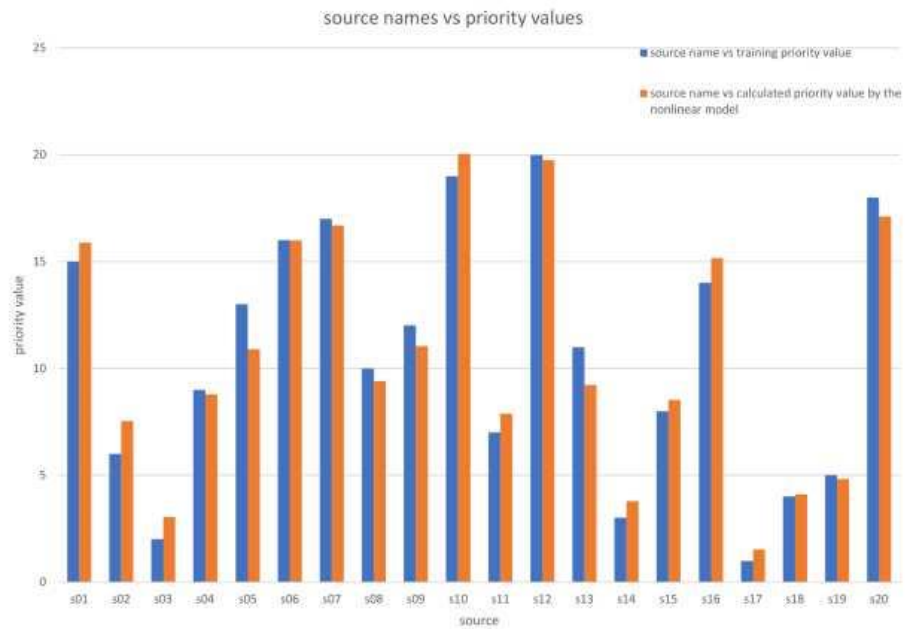


Рисунок 4.5 – Порівняння значень пріоритету, отриманих в результаті навчання та розрахованих за нелінійною моделлю

Таблиця 4.3 – Результати використання fitnlm з рівнянням (4.1)

Ім'я	Значення
X	0,82437
Y	0,34212
Z	0,029426




Рисунок 4.6 – Перехресна валідація




Рисунок 4.7 – Залежність MAE від кількості епох

#### 4.6.3 Точність моделі

Для того, щоб виміряти точність моделей, як для множинної лінійної регресії, так і для нелінійної моделі регресії, використано R-Squared і Adjusted R-Squared (таблиця 4.4). Значення R-Squared для моделі множинної лінійної регресії становить 0,979, а скориговане значення R-Squared становить 0,975. При цьому для моделі нелінійної регресії значення R-Squared становить 0,972, а значення скоригованого R-Squared становить 0,969. Крім того, таблиця 4.4 показує, що середнє значення точності для моделі Python Neural Network становить 96,58%, а стандартне відхилення становить 2,3%, тоді як середнє значення для MAE становить 0,083.

Рисунок 4.8 показує, що криві точності навчання, і криві тестування сходяться до 100%. З іншого боку, рисунок 4.9 показує, що і втрати на навчання, і втрати на тестування збігаються до 0. Рисунок 4.7 показує, що значення MAE збігається до 0.

Таблиця 4.4 – Значення вимірювання точності моделей

Модель	Міра точності	Значення
Множинна лінійна	R-Squared	0,979

регресія	Adjusted R-Squared	0,975
Нелінійна регресія	R-Squared	0,972
	Adjusted R-Squared	0,969
Модель нейронної мережі Python	середнє значення точності	96,58%
	стандартне відхилення	2,3%
	середнє значення MAE	0,083




Рисунок 4.8 – Залежність точності тренування і тестування від кількості епох




Рисунок 4.9 – Залежність втрат навчання і тестування від кількості епох

## ВИСНОВКИ

Підтримка електроенергії є критичною проблемою, особливо в країнах, що розвиваються, з дуже обмеженими можливостями та ресурсами. Проте все більша залежність від електричних приладів створює багато проблем для операторів, щоб оптимально усунути будь-яку несправність за мінімальний час. Навіть з урахуванням численних досліджень, проведених у цій галузі, дуже мало людей були зацікавлені в мінімізації тривалості несправності, особливо в країнах, що розвиваються з дуже обмеженими ресурсами. Оскільки прийняття рішень вимагає достатньої кількості інформації за мінімальний час, інтеграція інформаційних технологій з існуючими електричними мережами є найбільш доцільною.

У цій роботі запропоновані точні та ефективні моделі оцінки перерозподілу навантаження. Хоча існує декілька методів моделювання, запропоновані в цій роботі методи моделювання базуються на моделях машинного навчання: множинна лінійна регресія, нелінійна регресія та моделі нейронної мережі класифікатора.

Новизна цієї роботи полягає в тому, що вона впроваджує відмовостійкий підхід, який спирається на машинне навчання та систему диспетчерського контролю та збору даних (SCADA). Мета цього підходу полягає в тому, щоб допомогти електророзподільчим компаніям підтримувати електроенергію для клієнтів і скоротити тривалість несправності з багатьох годин до мінімально можливого часу. Робота виконана на основі реальних даних розумних мереж, розбитих на зони близько 20 трансформаторів. Вхідні дані моделей, зібрані з датчиків, розміщених в електромережі, роблять мережу здатною перерозподіляти навантаження за достатніми стратегіями. Для перевірки моделей було використано два потужних інструменти моделювання: MATLAB і Python. Результати показали точність близько 97% зі стандартним відхиленням 2,3%.

Також було детально представлено перерозподіл навантаження. Завдяки таким добрим результатам вони підтверджують дієвість запропонованої моделі щодо мінімізації тривалості збою, допомагаючи системі виконувати ідеальні дії в оптимальний час.

Отже, із застосуванням будь-якої із запропонованих методик в електромережі це може допомогти підвищити ефективність і сталість електроенергії в країнах, що розвиваються.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. L. Bird, M. Milligan, and D. Lew, “Integrating variable renewable energy: Challenges and solutions,” Report No. NREL/TP-6A20-60451 [National Renewable Energy Lab. (NREL), Golden, CO, 2013].
2. M. Raissi, P. Perdikaris, and G. E. Karniadakis, “Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations,” *J. Comput. Phys.* 378, 686-707 (2019).
3. B. Huang and J. Wang, “Applications of physics-informed neural networks in power systems—A review,” *IEEE Trans. Power Syst.* 38, 572-588 (2022).
4. W. Liu, Z. Wang, X. Liu, N. Zeng, Y. Liu, and F. E. Alsaadi, “A survey of deep neural network architectures and their applications,” *Neurocomputing* 234, 11-26 (2017).
5. J. Zhou, G. Cui, S. Hu, Z. Zhang, C. Yang, Z. Liu, L. Wang, C. Li, and M. Sun, “Graph neural networks: A review of methods and applications,” *AI Open* 1, 57-81 (2020).
6. W. Liao, B. Bak-Jensen, J. R. Pillai, Y. Wang, and Y. Wang, “A review of graph neural networks and their applications in power systems,” *J. Mod. Power Syst. Clean Energy* 10, 345-360 (2021).
7. Tom RJ, Sankaranarayanan S. 2017. IoT based SCADA integrated with Fog for power distribution automation. In: 2017 12th Iberian Conference on Information Systems and Technologies (CISTI). Piscataway: IEEE, DOI 10.23919/CISTI.2017.7975732.
8. Skripcak T, Tanuska P. 2013. Utilisation of on-line machine learning for SCADA system alarms forecasting. In: 2013 science and information conference. 477-484.
9. Goldenberg N, Wool A. 2013. Accurate modeling of Modbus/TCP for

intrusion detection in SCADA systems. *International Journal of Critical Infrastructure Protection* 6(2):63-75 DOI 10.1016/j.ijcip.2013.05.001.

10. Hu RL. 2016. *Machine Learning to Scale Fault Detection in Smart Energy Generation and Building Systems*. Ph.D. dissertation. Berkeley, CA: UC Berkeley.

11. Mookiah L, Dean C, Eberle W. 2017. Graph-based anomaly detection on smart grid data. In: *Proceedings of the Thirtieth International Florida Artificial Intelligence Research Society Conference*. 306-311.

12. Guo C, Li F, Tian Z, Guo W, Tan S. 2020. Intelligent active fault-tolerant system for multi-source integrated navigation system based on deep neural network. *Neural Computing & Applications* 32(22):16857-16874 DOI 10.1007/s00521-018-03975-z.

13. Li L, Ota K, Dong M. 2017. Everything is image: CNN-based short-term electrical load forecasting for smart grid. In: *2017 14th International Symposium on Pervasive Systems, Algorithms and Networks & 2017 11th International Conference on Frontier of Computer Science and Technology & 2017 Third International Symposium of Creative Computing (ISPAN-FCST-ISCC)*. 344-351.

14. Wang X, Yaz EE. 2016. Smart Power Grid Synchronization With Fault Tolerant Nonlinear Estimation. *IEEE Transactions on Power Systems* 31(6):4806-4816.

15. Gilbert EPK, Lydia M, Baskaran K, Rajsingh EB. 2019. Trust aware fault tolerant prediction model for wireless sensor network based measurements in Smart Grid environment. *Sustainable Computing: Informatics and Systems* 23:29-37 DOI 10.1016/j.suscom.2019.06.001.

16. Matsukawa S, Ninagawa C, Morikawa J, Inaba T, Kondo S. 2019. Stable Segment Method for Multiple Linear Regression on Baseline Estimation for Smart Grid Fast Automated Demand Response. In: *2019 IEEE PES innovative smart grid technologies Asia, ISGT 2019*. Piscataway: IEEE, 2571-2576 DOI 10.1109/ISGT-Asia.2019.8881088.

17. Ahmad T, Chen H. 2018. Potential of three variant machine-learning

models for forecasting district level medium-term and long-term energy demand in smart grid environment. *Energy* 160:1008-1020 DOI 10.1016/j.energy.2018.07.084.

18. Hafeez G, Alimgeer KS, Khan I. 2020. Electric load forecasting based on deep learning and optimized by heuristic algorithm in smart grid. *Applied Energy* 269:114915 DOI 10.1016/j.apenergy.2020.114915.

19. Lei J, Liu C, Jiang D. 2019. Fault diagnosis of wind turbine based on Long Short-term memory networks. *Renewable Energy* 133(C):422-432.

20. M. Farivar and S. H. Low, "Branch flow model: Relaxations and convexification—Part I," *IEEE Trans. Power Syst.* 28, 2554-2564 (2013).

21. A. Bergen and V. Vittal, *Power Systems Analysis* (Prentice Hall, 2000).

22. G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang, and L. Yang, "Physics-informed machine learning," *Nat. Rev. Phys.* 3, 422-440 (2021).

23. K. Lehmann, A. Grastien, and P. Van Hentenryck, "Ac-feasibility on tree networks is np-hard," *IEEE Trans. Power Syst.* 31, 798-801 (2015).

24. P. Van Hentenryck, "Machine learning for optimal power flows," *Tutorials Oper. Res.* 62-82 (2021).

25. D. K. Molzahn and I. A. Hiskens et al., "A survey of relaxations and approximations of the power flow equations," *Found. Trends Electr. Energy Syst.* 4, 1-221 (2019).

26. F. Hasan, A. Kargarian, and A. Mohammadi, "A survey on applications of machine learning for optimal power flow," in *IEEE Texas Power and Energy Conference (TPEC)* (IEEE, 2020).

27. R. Nellikkath and S. Chatzivasileiadis, "Physics-informed neural networks for ac optimal power flow," *Electr. Power Syst. Res.* 212, 108412 (2022).

28. S. Chatzivasileiadis, A. Venzke, J. Stiasny, and G. Misyris, "Machine learning in power systems: Is it time to trust it?," *IEEE Power Energy Mag.* 20, 32-41 (2022).

29. K. Dehghanpour, Z. Wang, J. Wang, Y. Yuan, and F. Bu, "A survey on state estimation techniques and challenges in smart distribution systems," *IEEE*

Trans. Smart Grid 10, 2312-2322 (2018).

30. A. Abur and A. Exposito, Power System State Estimation: Theory and Implementation, Power Engineering (Willis) (CRC Press, 2004).

31. D. Jannach, M. Zanker, A. Felfernig, and G. Friedrich, Recommender Systems: An Introduction (Cambridge University Press, 2010).

32. P. L. Donti, Y. Liu, A. J. Schmitt, A. Bernstein, R. Yang, and Y. Zhang, "Matrix completion for low-observability voltage estimation," IEEE Trans. Smart Grid 11, 2520-2530 (2019).

33. M. Markovic, A. Florita, and B.-M. Hodge, "Matrix completion for improved observability in low-voltage distribution grids," in IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm) (IEEE, 2021).

34. R. Madbhavi, H. S. Karimi, B. Natarajan, and B. Srinivasan, "Tensor completion based state estimation in distribution systems," in IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT) (IEEE, 2020).

35. M. I. Jordan and T. M. Mitchell, "Machine learning: Trends, perspectives, and prospects," Science 349, 255-260 (2015).

36. Q. Wang, Y. Ma, K. Zhao, and Y. Tian, "A comprehensive survey of loss functions in machine learning," Ann. Data Sci. 9, 187-212 (2020).

37. F. Emmert-Streib and M. Dehmer, "Taxonomy of machine learning paradigms: A data-centric perspective," Wiley Interdiscip. Rev. 12, e1470 (2022).

38. T. Jebara, Machine Learning: Discriminative and Generative (Springer Science & Business Media, 2012), Vol. 755.

39. Zolotova I, Landryova L. 2000. Scada/HMI systems and emerging technologies. IFAC Proceedings 33(1):17-20.

40. Bonomi F, Milito R, Zhu J, Addepalli S. 2012. Fog computing and its role in the internet of things. In: Proceedings of the first edition of the MCC workshop on mobile cloud computing. 13-16.

41. Vilas VG, Muralidhara V, Bakre SM, Velhal V. 2018. Smart meter

modelling and fault location communication in smart grid. *Majlesi Journal of Electrical Engineering* 12(2):55-62.

42. Pendlebury F, Pierazzi F, Jordaney R, Kinder J, Cavallaro L. 2018. Enabling Fair ML Evaluations for Security. In: *CCS'18: proceedings of the 2018 ACM SIGSAC conference on computer and communications security*. New York: ACM, 2264-2266 DOI 10.1145/3243734.3278505.

43. Mohammed AA, Umaashankar V. 2018. Effectiveness of hierarchical softmax in large scale classification tasks. In: *2018 International conference of advanced computer communization informatics, ICACCI 2018*, No. 1. 1090-1094 DOI 10.1109/ICACCI.2018.8554637

44. Горба А.А., Павлов О.С., Старов О.Є. Оптимізація продуктивності мережі на основі засобів машинного навчання // «Системи управління навігації та зв'язку», – Випуск 2 (76), – Полтава, Національний університет “Полтавська політехніка імені Юрія Кондратюка”, – 2024. – С. 107-111.