

**МАГІСТЕРСЬКА РОБОТА**

**МР. ШМ - 19.00.00.000 ПЗ**

**Група ШМ-24-1**

**Лянг Андрій**

**2025**

**Івано-Франківський національний технічний університет нафти і газу**

Факультет інформаційних технологій

Кафедра інженерії програмного забезпечення

**Лянг Андрій Васильович**

(прізвище, ім'я, по батькові)

УДК 004.9  
(індекс)

## **МАГІСТЕРСЬКА РОБОТА**

**Моделі та методи застосування нейромереж в задачах**

**електричної інженерії**

(назва роботи)

**Інженерія програмного забезпечення**

(назва освітньої програми)

**121 - Інженерія програмного забезпечення**

(шифр і назва спеціальності)

**Лянг А.В.**

(підпис, ініціали та прізвище здобувача освітнього ступеня)

**Науковий керівник Корнута Володимир Андрійович, к.т.н., доцент**

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

**Допущено до захисту**

Завідувач кафедри

доц. Бандура В.В.

(посада) (підпис) (дата) (ініціали та прізвище)

**Нормоконтроль**

доц. Вовк Р.Б.

(посада) (підпис) (дата) (ініціали та прізвище)

Робота містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело

Івано-Франківськ – 2025

Івано-Франківський національний технічний університет нафти і газу

Факультет інформаційних технологій

Кафедра інженерії програмного забезпечення

Освітній рівень магістр

Спеціальність 121 – Інженерія програмного забезпечення

ЗАТВЕРДЖУЮ:

Зав. кафедрою

ІПЗ

доц.

В.В. Бандура

“ 04 ” вересня 2025 р.

# ЗАВДАННЯ

## НА МАГІСТЕРСЬКУ РОБОТУ СТУДЕНТУ

Лянгу Андрію Васильовичу

(прізвище, ім'я, по-батькові)

**1. Тема магістерської роботи “ Моделі та методи застосування нейромереж в задачах електричної інженерії”**

керівник проекту (роботи) Корнута Володимир Андрійович, к.т.н., доцент

затверджені наказом закладу вищої освіти від “ 05 ” листопада 2025 р. № 695/7

**2. Строк подання студентом проекту (роботи) 15 грудня 2025 р.**

**3. Вихідні дані до проекту (роботи) Теоретичні концепції та формальні моделі побудови та функціонування інформаційних нейромережових технологій**

**4. Зміст розрахунково - пояснювальної записки(перелік питань, які потрібно розробити)**

1. Аналіз предметної області застосування нейромереж в електричній інженерії

2. Дослідження моделей штучних нейронних мереж для застосування в електричній інженерії

3. Методологія автоматизованого моніторингу ліній електропередач на основі ЗНМ

4. Оцінка пропонуваного рішення застосування нейронної мережі для електричної інженерії

**5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень)**

1. Шари згорткової нейронної мережі на прикладі VGG16 (рис. 2.1)

2. Функція активації ReLU (рис. 2.2)

3. Візуальне представлення розділення набору даних (рис. 2.3)

4. Робочий процес автоматизованої ідентифікації об'єктів у зонах електромереж (рис. 2.4)

5. Схематична діаграма розташування смуг (рис. 2.5)

## 6. Консультанти розділів проекту (роботи)

Розділ	Консультант	Підпис, дата
Перевірка на плагіат	доц., к.т.н. Вовк Р.Б.	

7. Дата видачі завдання 04 вересня 2025 р.

Керівник \_\_\_\_\_  
(підпис)

Завдання прийняв до виконання \_\_\_\_\_  
(підпис)

## КАЛЕНДАРНИЙ ПЛАН

№ п/п	Назви етапів магістерської роботи	Строк виконання етапів роботи	Примітка
1	Підбір і вивчення літератури по темі магістерської роботи	17.09.2025	виконано
2	Аналіз предметної області застосування нейромереж в електричній інженерії	29.09.2025	виконано
3	Дослідження моделей штучних нейронних мереж для застосування в електричній інженерії	19.10.2025	виконано
4	Методологія автоматизованого моніторингу ліній електропередач на основі ЗНМ	10.11.2025	виконано
5	Оцінка пропонованого рішення застосування нейронної мережі для електричної інженерії	16.11.2025	виконано
6	Затвердження пояснювальної записки роботи завідувачем кафедри	14.12.2025	виконано

Студент – магістр \_\_\_\_\_  
(підпис)

Керівник роботи \_\_\_\_\_  
(підпис)

## АНОТАЦІЯ

**Магістерська робота:** 75 с., 24 рис., 4 табл., 44 джерела.

**Тема:** Моделі та методи застосування нейромереж в задачах електричної інженерії

**Мета магістерської роботи** - розроблення та дослідження моделей і методів застосування нейронних мереж для автоматизованого моніторингу та виявлення пошкоджень в електричних мережах.

**Об'єкт дослідження** - процеси моніторингу та діагностики розподільних електричних мереж із використанням методів штучного інтелекту.

**Предмет дослідження** - моделі, методи та алгоритми штучних нейронних мереж, зокрема згорткових нейронних мереж, що застосовуються для автоматизованого виявлення дефектів та пошкоджень ліній електропередач на основі обробки зображень.

### **Результати дослідження**

В роботі представлено методологію застосування згорткових нейронних мереж для моніторингу електроенергетичних об'єктів та удосконаленні методів попередньої обробки зображень для підвищення якості розпізнавання інфраструктурних елементів.

### **Висновок**

Запропонована модель на основі нейронних мереж демонструє високий рівень ефективності, гнучкості та адаптивності, що робить її перспективною для практичного застосування в системах автоматизованого моніторингу електроенергетичних об'єктів

**ШТУЧНИЙ ІНТЕЛЕКТ; НЕЙРОННА МЕРЕЖА; ЗГОРТКОВА НЕЙРОННА МЕРЕЖА; ГЛИБОКЕ НАВЧАННЯ; ЕЛЕКТРИЧНА ІНЖЕНЕРІЯ; МОНІТОРИНГ ЛІНІЙ ЕЛЕКТРОПЕРЕДАЧ; ТЕХНІЧНЕ ОБСЛУГОВУВАННЯ; АВТОМАТИЗАЦІЯ.**

## ABSTRACT

**Master Thesis:** 75 pp., 24 fig., 4 tab., 44 sources.

**Topic:** Models and methods of applying neural networks in electrical engineering tasks

**The purpose of the master's thesis** is to develop and study models and methods of applying neural networks for monitoring and detecting automated damage in electrical networks.

**The object of the study** is the processes of monitoring and diagnosing distribution electrical networks using artificial intelligence methods.

**The subject of the study** is models, methods and algorithms of artificial neural networks, in particular convolutional neurons, which are used for automated cleaning of defects and damage to power transmission lines based on network image processing.

### **Research results**

The paper presents a methodology for applying convolutional neural networks to monitor energy facilities and improve image preprocessing methods to improve the quality of recognition of infrastructure elements.

### **Conclusion**

The proposed model based on neural networks demonstrates a high level of efficiency, flexibility and adaptability, which makes it promising for practical application in automated monitoring systems for energy facilities.

**ARTIFICIAL INTELLIGENCE; NEURAL NETWORK;  
CONVULGATORY NEURAL NETWORK; DEEP LEARNING;  
ELECTRICAL ENGINEERING; POWER LINE MONITORING;  
MAINTENANCE; AUTOMATION.**

## ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ .....	10
ВСТУП.....	11
РОЗДІЛ 1. АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖ В ЕЛЕКТРИЧНІЙ ІНЖЕНЕРІЇ .....	15
1.1. Методологія застосування згорткових нейронних мереж для автоматизованого виявлення пошкоджень ліній електропередач .....	15
1.2. Оптимізація експлуатації енергетичної інфраструктури на основі нейронних мереж .....	16
1.2.1. Проблематика застарілості та надійності мережі .....	17
1.2.2. Інноваційні методи обслуговування на основі штучного інтелекту .....	17
1.2.3. Методологія дослідження .....	18
1.3. Елементи та конфігурація розподільних електричних мереж.....	18
1.3.1. Технічні характеристики компонентів .....	19
1.3.2. Загрози та надійність функціонування мережі .....	20
1.4. Вдосконалення процедур інспектування та обслуговування розподільних електричних мереж.....	21
1.5. Ефективність застосування безпілотних літальних апаратів для моніторингу електричної інфраструктури.....	22
1.5.1. Переваги інтеграції БПЛА в операційну діяльність .....	23
1.5.2. Синергія БПЛА та глибокого навчання.....	24
Висновки до розділу .....	24
РОЗДІЛ 2. ДОСЛІДЖЕННЯ МОДЕЛЕЙ ТА АЛГОРИТМІВ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ЗАСТОСУВАННЯ В ЕЛЕКТРИЧНІЙ ІНЖЕНЕРІЇ .....	26
2.1. Основи штучних нейронних мереж та їх застосування у комп'ютерному зорі .....	26

2.1.1. Архітектура та принцип навчання нейронних мереж .....	26
2.1.2. Згорткові нейронні мережі (ЗНМ) .....	27
2.1.3. Методологія навчання та валідації моделі .....	30
2.2. Актуальні дослідження та інновації у сфері застосування методів глибокого навчання для обслуговування енергетичної інфраструктури.....	31
2.2.1. Підвищення ефективності та надійності систем .....	31
2.2.2. Аналіз інтерпретованості нейронних мереж (Explainable AI).....	31
2.2.3. Конкретні технологічні розробки .....	32
2.3. Виклики та перспективи автоматизації інспекції електроенергетичної інфраструктури за допомогою БПЛА .....	37
2.4. Методологія автоматизованого моніторингу ліній електропередач на основі БПЛА та згорткових нейронних мереж .....	38
2.4.1. Програмне забезпечення та згорткова нейронна мережа .....	38
2.4.2. Вхідні дані з ресурсу Kaggle .....	39
2.4.3. Попередня обробка .....	40
2.4.4. Навчання моделі .....	41
2.4.5. Тестування моделі .....	41
Висновки до розділу .....	42

## РОЗДІЛ 3. ОЦІНКА ПРОПОНОВАНОГО РІШЕННЯ ЗАСТОСУВАННЯ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ЗАДАЧ ЕЛЕКТРИЧНОЇ ІНЖЕНЕРІЇ .....

3.1. Фактори, що впливають на продуктивність нейронних мереж у задачі детекції ліній електропередач .....	43
3.1.1. Фактори ідентифікації та виявлення.....	43
3.1.2. Складність нейронів: функція активації.....	44
3.1.3. Нейрони на кількість шарів.....	44
3.1.4. Нормалізація навчальних даних.....	45
3.2. Аналіз результатів експериментального дослідження детекції ліній електропередач з використанням нейромереж.....	46
3.2.1. Ідентифікація ліній електропередач .....	47

3.2.2. Точність ідентифікації ліній електропередач.....	48
3.2.3. Ефективність виявлення стану ліній електропередач.....	51
3.2.4. Ефективність моделі за різних світлових умов .....	53
3.3. Методи та підходи оптимізації розпізнавання об'єктів .....	57
Висновки до розділу .....	61
ВИСНОВКИ .....	63
ПЕРЕЛІК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ.....	66

## ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

NN - Neural Network - Нейронна мережа

ReLU - Rectified Linear Unit - функція активації

UAV - Unmanned Aerial Vehicle - Безпілотний літальний апарат

FPGA - Field-Programmable Gate Array - Програмована користувачем  
вентильна матриця

ASIC - Application-Specific Integrated Circuit - Спеціалізована  
інтегральна схема

PL - Power Line - Лінія електропередач (ЛЕП)

Adam - Adaptive Moment Estimation - Оцінка адаптивного моменту

Max Pooling - операція згорткових шарів

## ВСТУП

### **Актуальність теми.**

Сучасний етап розвитку електроенергетичної галузі характеризується глибокими технологічними трансформаціями, зумовленими впровадженням концепцій цифрової енергетики, інтелектуальних мереж (Smart Grid) та штучного інтелекту (AI). Розвиток великих енергосистем супроводжується ускладненням їхньої структури, зростанням навантажень, а також підвищеними вимогами до надійності, стабільності та безпеки енергопостачання. Традиційні підходи до діагностики, моніторингу та обслуговування енергетичної інфраструктури виявляються недостатньо ефективними в умовах динамічного зростання складності мереж і обсягів даних, що потребують обробки.

Використання нейромережевих технологій, зокрема згорткових нейронних мереж (CNN), відкриває нові можливості для автоматизації процесів виявлення дефектів, класифікації технічного стану обладнання та прогнозування можливих відмов у системах електропостачання. Застосування глибокого навчання в поєднанні з технологіями комп'ютерного зору та безпілотними літальними апаратами (БПЛА) створює передумови для переходу від реактивного до прогностичного управління станом електричної інфраструктури.

У рамках роботи досліджуються моделі, алгоритми й методи побудови нейронних мереж для задач електричної інженерії, спрямовані на підвищення ефективності моніторингу та обслуговування ліній електропередач. Здійснюється аналіз сучасних технологій, визначаються оптимальні архітектурні рішення та проводиться експериментальна перевірка запропонованого підходу з використанням реальних даних.

Актуальність дослідження зумовлена необхідністю підвищення надійності, ефективності та безпеки експлуатації електроенергетичних систем у контексті глобальної цифрової трансформації. В умовах зростання

обсягів споживання електроенергії, старіння інфраструктури та нестабільності енергоринку виникає потреба у створенні інтелектуальних систем моніторингу та діагностики, здатних працювати в реальному часі та приймати рішення без участі людини.

Традиційні методи контролю технічного стану ліній електропередач базуються переважно на візуальному інспектуванні та ручній обробці даних, що є трудомістким і схильним до помилок процесом. Застосування нейронних мереж дозволяє автоматизувати аналіз зображень, отриманих з БПЛА або стаціонарних камер, забезпечити швидке виявлення пошкоджень і мінімізувати людський фактор.

Крім того, у світовій енергетиці спостерігається тенденція до впровадження систем Predictive Maintenance (прогностичного обслуговування), що базуються на аналізі великих даних (Big Data) і алгоритмах машинного навчання. Тому використання нейромереж у сфері електричної інженерії є не лише актуальним, а й необхідним напрямом розвитку сучасних енергетичних технологій.

**Метою магістерської роботи** є розроблення та дослідження моделей і методів застосування нейронних мереж для автоматизованого моніторингу та виявлення пошкоджень в електричних мережах.

**Об'єктом дослідження** є процеси моніторингу та діагностики розподільних електричних мереж із використанням методів штучного інтелекту.

**Предметом дослідження** є моделі, методи та алгоритми штучних нейронних мереж, зокрема згорткових нейронних мереж, що застосовуються для автоматизованого виявлення дефектів та пошкоджень ліній електропередач на основі обробки зображень.

**Для досягнення поставленої мети у роботі вирішуються такі основні завдання:**

- Провести аналіз предметної області застосування нейронних мереж в електричній інженерії.

- Дослідити архітектури та принципи навчання штучних нейронних мереж, зокрема згорткових, у задачах комп'ютерного зору.

- Розробити методологію автоматизованого моніторингу ліній електропередач із використанням БПЛА та нейронних мереж.

- Провести експериментальні дослідження продуктивності нейромережових моделей для задач виявлення пошкоджень електричних мереж.

- Оцінити вплив різних факторів на точність і стабільність роботи моделі.

### **Методи дослідження**

У роботі застосовано такі наукові методи:

- аналітичний метод — для дослідження теоретичних основ нейронних мереж і методів глибокого навчання;

- системний аналіз — для узагальнення підходів до побудови інтелектуальних систем моніторингу;

- експериментальне моделювання — для побудови, навчання та тестування згорткової нейронної мережі;

- обчислювальні методи штучного інтелекту — для обробки зображень, класифікації та виявлення об'єктів;

- статистичний аналіз — для оцінювання точності, стабільності та ефективності розробленої моделі.

**Наукова новизна магістерської роботи** полягає у розробленні методології застосування згорткових нейронних мереж для моніторингу електроенергетичних об'єктів на основі даних, отриманих із БПЛА та удосконаленні методів попередньої обробки зображень для підвищення якості розпізнавання інфраструктурних елементів у змінних умовах освітлення.

### **Практичне застосування результатів**

Результати дослідження можуть бути використані у системах технічного моніторингу та інспектування електроенергетичних мереж для

автоматичного виявлення пошкоджень та при розробці інтелектуальних систем керування інфраструктурою Smart Grid.

**Структура магістерської роботи.** Робота складається зі вступу, трьох розділів та висновків. Загальний обсяг роботи становить 101 сторінку, і містить 20 рисунків, 5 таблиць, список використаних джерел із 54 найменувань.

# **РОЗДІЛ 1. АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖ В ЕЛЕКТРИЧНІЙ ІНЖЕНЕРІЇ**

## **1.1. Методологія застосування згорткових нейронних мереж для автоматизованого виявлення пошкоджень ліній електропередач**

Обслуговування та ремонт електромереж є критично важливими послугами для забезпечення безперебійного функціонування систем електропостачання. Оператори електромереж прагнуть мінімізувати час простою та перерви в електропостачанні, оскільки електроенергія є необхідною умовою для функціонування сучасних технологічних процесів, як у побутовій (приготування їжі, охолодження, гаряче водопостачання), так і в інституційній сферах (навчальні заклади, медичні установи, оборонні об'єкти). Аналіз поточної електроенергетичної інфраструктури часто свідчить про значну зношеність мережевих компонентів, що потребують планової заміни. Крім того, інфраструктура постійно піддається ризику пошкоджень, які можуть виникати як внаслідок звичайних експлуатаційних відмов ліній електропередач, так і внаслідок великомасштабних впливів, спричинених стихійними лихами.

У контексті необхідності підвищення ефективності обслуговування, а також заміни застарілих компонентів та виконання профілактичних ремонтних робіт, застосування нейронних мереж пропонує інноваційний підхід до оптимізації цих процесів. Зокрема, використання безпілотних літальних апаратів (БПЛА) у поєднанні з нейронними мережами дозволяє автоматизувати ідентифікацію та класифікацію стану ліній електропередач, розрізняючи нормально функціонуючі та пошкоджені ділянки.

Це дослідження зосереджено на застосуванні згорткових нейронних мереж (ЗНМ) та економічно ефективних БПЛА для ідентифікації та виявлення пошкоджень ліній електропередач, що забезпечують електроенергією кінцевих споживачів. БПЛА виступають у ролі платформи

для отримання вхідних візуальних даних, які подаються на нейронні мережі для автоматичної оцінки стану інфраструктури. Архітектура цих нейронних мереж, що складається з багат шарової структури, спеціально адаптована для цієї задачі, забезпечуючи високу ефективність ідентифікації та продуктивність виявлення.

Інтегрована система БПЛА-нейронна мережа здатна забезпечити більш ефективне планове обслуговування завдяки розширенню охоплення території, підвищенню доступності інспекційних даних та скороченню часу між виявленням несправності та початком ремонтних робіт.

Ключовою перевагою є підвищення безпеки персоналу, що здійснює обслуговування, а також прискорення реагування на аварійні ситуації, особливо під час стихійних лих. У сучасних умовах необхідне впровадження інтелектуальних рішень та ефективних методів реагування для обслуговування територій, що зростають, та районів з обмеженими ресурсами.

## **1.2. Оптимізація експлуатації енергетичної інфраструктури на основі нейронних мереж**

Електроенергетична мережа є критично важливим національним ресурсом, що забезпечує функціонування усіх ключових сфер життєдіяльності, включно з транспортом, освітою, рекреацією та медичним обслуговуванням. Енергопостачання реалізується через багаторівневу систему: від генеруючих потужностей до споживачів, використовуючи високовольтні магістральні лінії, підстанції та розподільні мережі нижчої напруги. Забезпечення цілодобової та безперебійної роботи цієї інфраструктури є пріоритетним завданням для енергопостачальних компаній. Будь-які порушення у функціонуванні такої трильйонної інфраструктури можуть спричинити значні економічні збитки як для операторів, так і для кінцевих споживачів.

### *1.2.1. Проблематика застаріlosti та надійності мережі*

Значна частина сучасної електроенергетичної інфраструктури була побудована у середині ХХ століття (1950-х – 1960-х роках), і наразі перевищує рекомендований термін експлуатації. Наприклад, у США стан електроінфраструктури у 2017 році був оцінений Американським товариством цивільних інженерів (ASCE) як "D+". Оціночна вартість повної заміни усієї рекомендованої до оновлення інфраструктури перевищує 5 трильйонів доларів. Така висока вартість та низька оцінка стану вимагають розробки інтелектуальних та економічно ефективних стратегій підтримки та експлуатації.

Крім експлуатаційного зносу, стихійні лиха (грози, урагани тощо) є значним чинником перебоїв в електропостачанні. За оцінками, до 90% від загального часу перерв у постачанні електроенергії споживачам пов'язані з подіями, що впливають на місцеві розподільні мережі. Навіть одинична подія, як-от падіння дерева на розподільну лінію, може призвести до відключення тисяч споживачів. Аналіз даних, зібраних з надійності електропостачання (NERC) за період 1984–2006 рр., показав, що майже 44% усіх зареєстрованих значних відключень були спричинені погодними умовами.

### *1.2.2. Інноваційні методи обслуговування на основі штучного інтелекту*

Враховуючи практичну неможливість швидкої та повної заміни застарілого обладнання в масштабах великих територій, необхідним є впровадження автоматизованих методів ідентифікації та виявлення несправностей.

Одним з перспективних рішень є використання гнучкості безпілотних літальних апаратів (БПЛА) для отримання візуальних даних (зображень), які слугують вхідними даними для моделі нейронної мережі. Ця модель, навчена ідентифікувати лінії електропередач, здатна автоматично оцінювати їх стан.

Аналогічний підхід може бути застосований для оперативної інспекції під час аварій, спричинених штормами чи стихійними лихами, дозволяючи відправляти БПЛА у небезпечні або важкодоступні зони. Здатність до надійної ідентифікації та виявлення в широкому діапазоні погодних та світлових умов може значно скоротити час, необхідний для обслуговування та відновлювальних робіт.

### *1.2.3. Методологія дослідження*

Подана робота зосереджена на дослідженні конфігурації та оцінці продуктивності згорткових нейронних мереж (ЗНМ) у поєднанні з БПЛА для ідентифікації та виявлення ліній електропередач із цільовою точністю понад 90% в різних умовах освітлення.

ЗНМ, що складаються з багат шарової архітектури, призначають різним об'єктам та їх характеристикам рівні важливості, що є ключовим для їх диференціації на зображеннях. Процес навчання моделі буде сфокусований на науково обґрунтованій конфігурації шарів мережі з урахуванням варіативності погодних та світлових умов. Під час тестування будуть зібрані метрики продуктивності для аналізу точності виявлення шляхом класифікації ліній електропередач як пошкоджених або непошкоджених.

Результати цього дослідження мають потенціал для революціонізації галузевих практик, сприяючи підвищенню ефективності обслуговування, гарантуванню безпеки технічного персоналу та забезпеченню надійності безперебійного електропостачання за допомогою штучного інтелекту.

## **1.3. Елементи та конфігурація розподільних електричних мереж**

Розподільні лінії електропередачі (ЛЕП) становлять завершальний етап у системі доставки електричної енергії до кінцевих споживачів. Діапазон робочої напруги цих ліній, як правило, варіюється від 2,4 кВ до 34,5 кВ.

Типова розподільна мережа є комплексною системою, що включає:

- Лінії електропередачі середньої напруги (первинна мережа).
- Розподільні підстанції.
- Трансформатори, змонтовані на опорах.
- Низьковольтні розподільні лінії (вторинна мережа).
- Облікові пристрої (лічильники).

Опори ЛЕП (стовпи) слугують основними несучими елементами для зазначених комунікацій та обладнання.




Рис. 1.1. Розподільні лінії електропередачі

### *1.3.1. Технічні характеристики компонентів*

#### 1. Первинна розподільна мережа (середня напруга)

У верхній частині опорної конструкції зазвичай розміщуються провідники, що формують трифазну систему розподілу електроенергії. Ця система, як правило, складається з трьох або чотирьох електричних ліній (три фази та, за необхідності, нейтральний провідник).

Більшість розподільних ліній виготовляється з високоміцного алюмінію. Перевагами алюмінію є його низька питома вага та економічна ефективність порівняно з міддю.

Провідники можуть бути неізольованими, вкритими (покритими) або ізольованими. У сучасних мережах поширені самонесні ізольовані проводи (СПП), що підвищують безпеку та надійність, особливо в умовах контакту з гілками дерев.

## 2. Трансформаторні пристрої

Нижче первинних розподільних ліній часто встановлюються розподільні трансформатори (стовпові або щоглові). Ці пристрої виконують ключову функцію зниження напруги (до стандартних значень, наприклад, 230/400 В) для безпосереднього постачання електроенергії побутовим та комерційним споживачам.

## 3. Вторинна розподільна мережа (низька напруга)

Від трансформаторів відходять низьковольтні лінії, що ведуть до точок підключення споживачів.

## 4. Телекомунікаційні лінії

Найнижчий ярус опорних стовпів зарезервовано для телекомунікаційних кабелів. Вони призначені для передачі даних і можуть бути виконані з:

- волоконно-оптичного матеріалу (для високошвидкісної передачі даних).
- мідного матеріалу (для традиційної телефонії та Інтернету).

Телекомунікаційні кабелі часто поміщаються у полімерний канал або захисну оболонку та кріпляться до сталевого несучого троса (троса-носія) для забезпечення механічної міцності та підтримки.

### *1.3.2. Загрози та надійність функціонування мережі*

Надійність функціонування розподільної мережі є критичною, оскільки вона є найбільш вразливою до зовнішніх впливів:

## 1. Вплив рослинності.

Контакт з гілками дерев є однією з основних причин коротких замикань та відключень.

## 2. Погодні явища.

Ожеледиця, сильний вітер та блискавки спричиняють механічні пошкодження провідників, ізоляторів та опор.

Необхідність мінімізації часу перерв у постачанні стимулює впровадження систем автоматизації розподільних мереж (DA) та інтелектуальних рішень, таких як використання БПЛА та нейронних мереж для проактивного моніторингу та діагностики.

### **1.4. Вдосконалення процедур інспектування та обслуговування розподільних електричних мереж**

Традиційні методи інспекції розподільних ліній електропередачі наразі значною мірою залежать від прямих польових оглядів, які є трудомісткими та тривалими. Найпоширеніші методи включають:

- Прямий доступ та сходження на опори, тобто фізичне підняття персоналу на опорні стовпи для детального візуального та тактильного обстеження компонентів.

- Використання пілотованої авіації - для інспектування високовольтних магістральних ліній, які з'єднують підстанції, залучаються пілотовані гелікоптери.

Ці методи є масштабно неефективними при обстеженні великих сегментів мережі. Обсяг інспекційних робіт, що перевищує 100 км., може вимагати декількох місяців для завершення силами однієї робочої бригади. З огляду на постійне розширення та ускладнення електроенергетичної мережі, завдання інспекції стає дедалі більш часозатратним і складним.

Частота та оперативність проведення профілактичних інспекцій та планового обслуговування часто ускладнюються через:

- Обмежений доступ і наявність важкодоступних географічних зон.

- Проведення ремонтних робіт ускладнюється в умовах стихійних лих, коли доступ до об'єктів може бути заблокований уламками. Крім того, при великомасштабних відключеннях може виникати дефіцит кваліфікованих ремонтних бригад відносно кількості необхідних втручань.

З метою підвищення ефективності, прискорення обслуговування та покращення ремонту, в електроенергетичній галузі активно досліджується інтеграція технологій безпілотних літальних апаратів (БПЛА) у поєднанні з навченими нейронними мережами. Цей синергетичний підхід дозволяє автоматизувати процес збору даних та їх аналізу, забезпечуючи швидку та точну діагностику стану інфраструктури, зокрема, в умовах підвищеного ризику або обмеженого фізичного доступу.

### **1.5. Ефективність застосування безпілотних літальних апаратів для моніторингу електричної інфраструктури**

Інтеграція безпілотних літальних апаратів (БПЛА) пропонує економічно ефективне рішення з низьким рівнем ризику для задоволення сучасних вимог до обслуговування та ремонту електроенергетичної інфраструктури. Операції з обслуговування можуть бути розділені на дві основні категорії, які різняться за рівнем ризику та оперативною необхідністю:

#### **1. Періодичне (планове) обслуговування**

Періодичне обслуговування характеризується мінімальним ризиком, оскільки, як правило, воно виконується за сприятливих погодних та світлових умов. У цій категорії відсутня безпосередня терміновість; бригади зосереджені на ідентифікації дефектів, які можуть бути включені до графіка подальших планових ремонтів.

#### **2. Критичне (аварійне) обслуговування**

Критичне обслуговування несе вищий ступінь ризику, оскільки воно спричинене пошкодженнями ліній електропередач, які виникли внаслідок екстремальних погодних умов або руйнівних подій. Використання БПЛА для інспекції в критичних ситуаціях, замість залучення людського персоналу, забезпечує значне зниження розрахункового ризику для працівників.



Рис. 1.2. Приклад використання БПЛА для моніторингу пошкоджень ЛЕП

#### *1.5.1. Переваги інтеграції БПЛА в операційну діяльність*

Застосування БПЛА забезпечує суттєве покращення оперативності та покриття обслуговування і ремонту.

Наведемо на опишемо наступні переваги:

##### 1. Безперешкодна інспекція.

БПЛА здатні долати значні відстані вздовж ліній електропередач, не перешкоджаючи фізичним об'єктам, таким як дорожня інфраструктура, забудовані території або скупчення уламків.

##### 2. Мінімальні вимоги до експлуатації.

Дрони вимагають мінімальної кількості попередніх умов для розгортання та не обмежені мінімальною висотою польоту, на відміну від пілотованої авіації.

### 3. Економічна ефективність.

Вартість експлуатації та обслуговування БПЛА є значно нижчою порівняно з витратами, пов'язаними з використанням спеціалізованих транспортних засобів, важкої техніки та оплатою праці ремонтних бригад.

### 4. Автоматизація та гнучкість.

Безпілотні літальні апарати можуть бути запрограмовані на автоматичне розгортання відповідно до графіка профілактичного обслуговування. Вони також демонструють вищу стійкість до неоптимальних погодних умов і можуть бути оперативно передислоковані або відкладені до моменту, коли умови польоту стануть сприятливими, мінімізуючи час простою.

#### *1.5.2. Синергія БПЛА та глибокого навчання*

Ключовим аспектом інноваційного підходу є інтеграція БПЛА з нейронними мережами. Зображення розподільних ліній, отримані під час польоту, можуть бути подані на навчену модель глибокого навчання. Ця модель здатна автоматично ідентифікувати та виявляти лінії електропередач та їхній стан у різних умовах освітлення та погоди.

У випадку, коли навчена нейронна мережа ідентифікує несправність або пошкоджену ділянку, генерується автоматичне сповіщення. Це дозволяє оператору електромережі оперативно інформувати ремонтну або бригаду, що значно прискорює процес локалізації проблеми та її усунення.

## **Висновки до розділу**

У першому розділі проведено ґрунтовний аналіз сучасного стану предметної області електричної інженерії в контексті інтеграції технологій

штучного інтелекту та нейронних мереж у процесі моніторингу, управління та обслуговування енергетичних систем. Розглянуто ключові напрямки, у яких застосування згорткових нейронних мереж (ЗНМ) демонструє значний потенціал підвищення ефективності та надійності електроенергетичної інфраструктури.

Проведений огляд методологій застосування ЗНМ для автоматизованого виявлення пошкоджень ліній електропередач дозволив встановити, що саме глибокі моделі комп'ютерного зору здатні забезпечити високоточну класифікацію та сегментацію зображень інфраструктурних об'єктів. Виявлено, що впровадження таких систем суттєво зменшує потребу в ручному інспектуванні та підвищує оперативність реагування на аварійні ситуації.

Таким чином, у першому розділі обґрунтовано доцільність і перспективність використання нейронних мереж в електричній інженерії, визначено основні проблеми предметної області та сформовано науково-методологічне підґрунтя для подальшого моделювання та розробки інтелектуальних систем технічного моніторингу.

## **РОЗДІЛ 2. ДОСЛІДЖЕННЯ МОДЕЛЕЙ ТА АЛГОРИТМІВ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ЗАСТОСУВАННЯ В ЕЛЕКТРИЧНІЙ ІНЖЕНЕРІЇ**

### **2.1. Основи штучних нейронних мереж та їх застосування у комп'ютерному зорі**

#### *2.1.1. Архітектура та принцип навчання нейронних мереж*

Штучні нейронні мережі (ШНМ) є обчислювальними моделями, інспірованими структурою біологічного мозку. Вони складаються з численних взаємопов'язаних штучних нейронів, що забезпечують передачу та обробку інформації. Ключова перевага НМ полягає у їхній здатності автоматично навчатися високоскладним нелінійним залежностям у масиві даних, що протиставляється необхідності жорсткого кодування (Hardcoding) сотень детермінованих правил для опису та ідентифікації об'єктів.

Фундаментальна перевага НМ над традиційними алгоритмами обробки зображень полягає в тому, що для надійної класифікації об'єкта не потрібно повного апріорного розуміння всіх необхідних ознак. НМ, навчаючись на репрезентативному наборі зразків, демонструє здатність до узагальнення та виявлення об'єктів, які не були безпосередньо представлені в навчальній вибірці (раніше небачені об'єкти).

Вибір гіперпараметрів моделі є критично важливим і має ґрунтуватися на глибокому розумінні конкретної задачі, яку вирішує мережа. Оптимізація гіперпараметрів дозволяє НМ самостійно вивчати релевантні особливості зображення (функції) під час ітераційного процесу навчання. З огляду на необхідність покриття всіх відомих варіантів умов, НМ є більш ефективним інструментом порівняно з ітеративним ручним коригуванням програмного коду. Завдяки здатності до узагальнення, нейронна мережа має вищу ймовірність досягнення підвищеної точності виявлення та зниження кількості хибнопозитивних спрацьовувань.

### 2.1.2. Згорткові нейронні мережі (ЗНМ)

Згорткові нейронні мережі (Convolutional Neural Networks, CNN) є спеціалізованим класом НМ, архітектура яких оптимально адаптована для роботи з двовимірними даними, такими як зображення. ЗНМ широко використовуються для задач ідентифікації та детекції об'єктів у комп'ютерному зорі.




Рис. 2.1. Шари згорткової нейронної мережі на прикладі VGG16

Вхідний шар згорткової нейронної мережі (Conv1) приймає RGB-зображення фіксованої просторової роздільної здатності  $224 \times 224$  пікселів.

Обробка вхідних даних здійснюється за допомогою послідовності згорткових шарів. У цих шарах використовуються фільтри (ядра) з мінімальним рецептивним полем розміром  $3 \times 3$  пікселів. У деяких варіаціях конфігурації також застосовується згортковий фільтр розміром  $1 \times 1$ , який реалізує лінійну трансформацію вхідних каналів з наступним застосуванням нелінійності.

Крок згортки (Stride): Фіксований на значенні 1 піксель.

Просторове доповнення (Padding): для шарів  $3 \times 3$  використовується доповнення (padding) зі значенням 1, що забезпечує збереження просторової роздільної здатності тензора ознак після операції згортки.

Просторове зменшення вибірки (downsampling) виконується за допомогою п'яти Max-Pooling шарів. Кожен шар Max-Pooling розміщується після стека одного або декількох згорткових шарів і застосовує операцію до вікна розміром  $2 \times 2$  пікселів з кроком (Stride) 2.

Після стека згорткових шарів, глибина якого варіюється залежно від конкретної архітектурної конфігурації, слідує три повністю з'єднані (Fully Connected) шари (FC).

Перші два FC-шари мають вихідну розмірність 4096 каналів (нейронів).

Третій FC-шар має розмірність 1000 каналів, що відповідає кількості класів у задачі класифікації (наприклад, ILSVRC).

Завершальним елементом мережі є шар Softmax для отримання розподілу ймовірностей належності до класів.

Усі приховані шари мережі (згорткові та повністю з'єднані) використовують функцію активації Rectified Linear Unit (ReLU).

Архітектура ЗНМ ґрунтується на послідовній комбінації:

- Згорткових шарів (Convolutional Layers): Використовують фільтри (ядра) для виконання операції згортки над вхідним зображенням, виділяючи локальні ознаки (Edge, Texture, Shape).

- Шари пулінгу (Pooling Layers): Застосовуються для зменшення просторової роздільної здатності вихідних карт ознак, що призводить до отримання більш щільного представлення даних. Цей механізм зниження вибірки є менш вимогливим до обчислювальних ресурсів (процесора та пам'яті) порівняно з алгоритмічними підходами, що базуються на великій кількості умовних операторів (IF-Else) та циклів. Хоча загальна модель ЗНМ може бути складною, вона забезпечує високу ефективність використання ресурсів.

Після кожного згорткового шару необхідно застосовувати шар активації. Найпоширенішою функцією активації є Rectified Linear Unit (ReLU), яка відповідає за введення нелінійності у систему, що складається з переважно лінійних операцій (згортка).

$$\text{Функція ReLU: } f(x) = \max(0, x).$$

Ця функція перетворює всі від'ємні значення активації на нуль, зберігаючи додатні значення, що сприяє ефективному навчанню мережі.




Рис. 2.2. Функція активації ReLU

Для подальшого зменшення розмірності використовується шар максимального пулінгу. Він застосовує фільтр певного розміру (наприклад,  $2 \times 2$ ) до входних даних (карт ознак) і повертає максимальне значення у кожному підрегіоні, покритому фільтром. Це зберігає найважливіші виділені ознаки, одночасно зменшуючи обсяг даних.

Завершальним етапом у типовій архітектурі ЗНМ є приєднання повністю з'єданого шару (FC Layer). Цей шар приймає векторні входні дані з попередніх шарів і формує N-вимірний вихідний вектор, де N відповідає загальній кількості класів, між якими повинна відбуватися класифікація (наприклад, "пошкоджена лінія" або "неушкоджена лінія").

### 2.1.3. Методологія навчання та валідації моделі

Для ефективного навчання моделі ЗНМ вхідний масив даних повинен бути розділений на три непересічні набори:



Рис. 2.3. Візуальне представлення розділення набору даних

- Набір даних для навчання (Training Set) - використовується як вхідний матеріал для нейронної мережі з метою ітеративного налаштування вагових коефіцієнтів та зсувів (біасів) усіх шарів моделі. Критично важливим є забезпечення репрезентативності навчального набору для забезпечення точної здатності моделі до узагальнення. Цей сегмент даних відповідає за навчання моделі.

- Набір даних для валідації (Validation Set) - це відокремлена частина даних, яка використовується для неупередженої оцінки продуктивності моделі під час самого процесу навчання. Тестування на валідаційному наборі надає інженерам можливість моніторингу, що дозволяє оцінити, наскільки ефективно модель функціонуватиме на невідомих даних перед фінальною оцінкою. Цей сегмент є меншим за навчальний і використовується для тонкого налаштування гіперпараметрів моделі та оцінки її продуктивності під час навчання.

- Тестовий набір даних (Test Set) - використовується лише один раз для фінальної, незалежної оцінки остаточної, неупередженої оцінки продуктивності або підгонки (Final Fit) навченої моделі. Цей набір повинен містити зразки, що охоплюють увесь спектр класів та варіацій даних, які можуть зустрітися в умовах реальної експлуатації.

## **2.2. Актуальні дослідження та інновації у сфері застосування методів глибокого навчання для обслуговування енергетичної інфраструктури**

В останні роки безпілотні літальні апарати (БПЛА) були успішно інтегровані в галузі, що вимагають підвищення операційної ефективності та безпеки персоналу. В енергетичному секторі БПЛА активно поєднуються з алгоритмами глибокого навчання для автоматизованої ідентифікації та виявлення ліній електропередач (ЛЕП).

### *2.2.1. Підвищення ефективності та надійності систем*

Прогрес у цій сфері включає розробку методів збільшення тривалості польоту БПЛА, зокрема, за рахунок оптимізації стратегій посадки. Крім того, активно досліджується автоматичне виявлення об'єктів у реальному часі для скорочення часу реагування на аварійні відключення електроенергії, навіть у середовищах із високим рівнем візуального зашумлення (захаращених середовищах).

Ключовою передумовою для практичної корисності цих методів є досягнення нейронними мережами високої точності класифікації та детекції. Дослідницька робота триває у напрямку розробки моделей, здатних виявляти структурні елементи ЛЕП, товщина яких становить лише кілька пікселів.

### *2.2.2. Аналіз інтерпретованості нейронних мереж (Explainable AI)*

Ефективне підвищення точності нейронних мереж вимагає глибокого розуміння внутрішніх механізмів їхньої роботи. В роботі [5] досліджували методи аналізу інформації, представлені всередині нейронних мереж, підкреслюючи, що повне розуміння внутрішніх процесів є необхідною умовою для оптимізації їхньої точності.

В дослідженні [6] автор запропонував метод аналізу інформації, представлені в багаторівневих нейронних мережах, спрямований на

визначення функції для кількісної оцінки ступеня залежності вихідних даних від вхідних. Це дозволяє оцінити, чи навчена мережа здатна виділяти ознаки, найбільш критичні для класифікації зображення. Оскільки нейронні мережі часто розглядаються як "чорний ящик", ці дослідження є важливими для розуміння внутрішньої структури та подальшого покращення продуктивності.

### *2.2.3. Конкретні технологічні розробки*

Автори в [7] зробили внесок у дослідження систем підтримки БПЛА для автоматичного виявлення ЛЕП, використовуючи зображення дистанційного зондування.

Вони запропонували метод, що включає кластеризацію на основі інтенсивності пікселів, з наступним застосуванням морфологічних операцій для виділення ліній.

Оцінка продуктивності показала, що метрики, отримані з матриці плутанини, наближаються до одиниці, що свідчить про високу ефективність запропонованого методу класифікації.

Всі об'єкти в коридорі лінії електропередачі, відстань до яких менша за безпечну, визначаються як перешкоди. Як показано на рис. 2.4, для виявлення перешкод у коридорі лінії електропередачі ми спочатку використовуємо зображення БПЛА та опорні точки (GCP) для отримання зовнішнього орієнтування зображень (EOI) за допомогою блочного врівноваження (BVA). Потім епіполярні зображення генеруються на основі параметрів відносного орієнтування стереозображень. Згодом пропонується PLAMES для вилучення 3D-векторів лінії електропередачі зі стереопар зображень, що складаються з відповідних зображень з різних смуг польоту, а для вилучення щільних хмар точок у межах коридору для 3D-реконструкції наземних об'єктів, включаючи крони дерев, будівлі та інші наземні об'єкти, застосовується напівпатчеве зіставлення на основі епіполярних обмежень (SPMESC). Нарешті, перешкоди автоматично ідентифікуються та

локалізуються шляхом розрахунку просторової відстані між лінією електропередачі та хмарою наземних точок, вилученою з оптичних зображень.

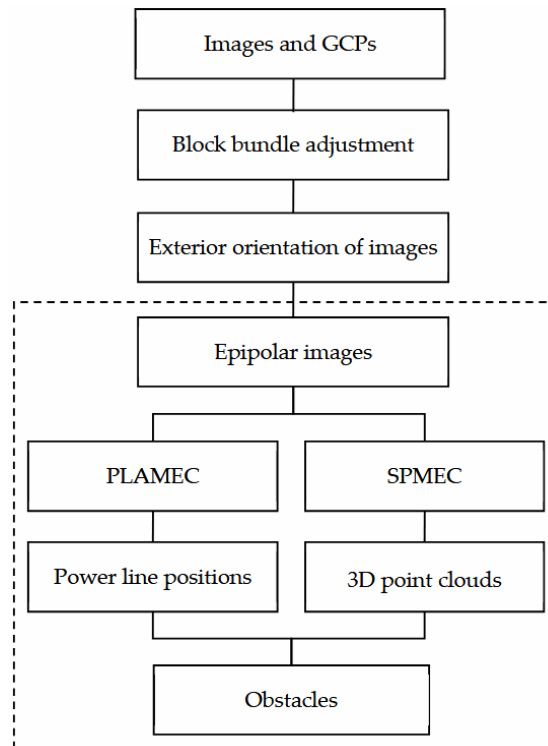


Рис. 2.4. Робочий процес автоматизованої ідентифікації об'єктів у захисних зонах електромереж

Під час інспекції коридору лінії електропередачі наявність перешкод, параметри польоту повинні бути розроблені відповідно до параметрів камери, встановленої на БПЛА. Висота польоту БПЛА повинна збалансовувати відстань між пікселями на землі (GSD) та експлуатаційну ефективність. Чим вище БПЛА над землею, тим вища ефективність фотозйомки та більшим стане значення GSD. Лінія електропередачі буде занадто тонкою для зображення через малий масштаб фотографії. Загалом, діаметр ліній електропередачі надвисокої напруги становить близько 4 см. Тому на практиці ми схильні проектувати висоту польоту відповідно до  $GSD \approx 4$  см. Переднє та бокове перекриття також є важливими параметрами, і ми рекомендуємо встановити як переднє, так і бокове перекриття на рівні 80%.

Високе переднє перекриття підвищить надійність методу автоматичного вимірювання опорних точок в аеротриангуляції (АТ). Високе бокове перекриття зменшить ризик того, що лінія електропередачі опиниться за межами зони перекриття стереозображень. Після визначення висоти польоту, а також переднього та бокового перекриття, БПЛА літає туди-сюди вздовж лінії електропередачі, збираючи дві смуги, як показано на рис. 2.5. Геоприв'язка зображень була здійснена за допомогою процесу блочного врівноваження та опорних точок.




Рис. 2.5. Схематична діаграма розташування смуг

Зелені крапки представляють центри камер, а сірі прямокутники під зеленими крапками – це зняті зображення у світових координатах. Маленькі крапки внизу – це проєктовані наземні точки, де колір представляє різні висоти, зазначені легендою праворуч на рисунку.

Діаметр лінії електропередачі невеликий (близько 4 см); отже, лінія електропередачі на зображенні дуже тонка і зазвичай становить приблизно від одного до трьох пікселів. Текстура однорідна, тоді як фон зображення складається зі складних текстур. Важко використовувати методи зіставлення зображень для пошуку відповідних точок вздовж лінії електропередачі. Ми пропонуємо PLAMES для виконання автоматичних вимірювань лінії електропередачі, оскільки наземні точки в стереопарах зображень повинні

бути розташовані вздовж відповідних епіполярних ліній. Рисунок 2.6 показує блок-схему запропонованого методу.

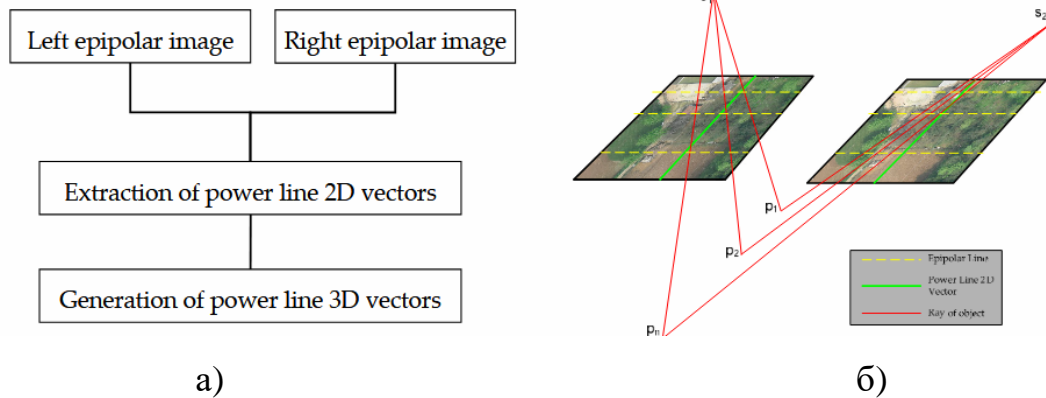


Рис. 2.6. Схематичні діаграми методу автоматичного вимірювання ліній електропередач. а) Блок-схема методу автоматичного вимірювання ліній електропередач на основі епіполярних обмежень (PLAMEC); б) Візуалізація PLAMEC.

Як показано на рис. 2.6 а, пара зображень з двох суміжних смуг вибирається як стереопара зображень, причому напрямок лінії електропередачі є приблизно перпендикулярним до напрямку епіполярної лінії.

Епіполярні зображення генеруються на основі умови компланарності, а параметри відносного орієнтування стереопари зображень розраховуються за допомогою алгоритму відносного орієнтування. Потім алгоритм автоматичного вилучення лінії електропередачі використовується для вилучення 2D-векторів ліній електропередачі з лівого та правого епіполярних зображень (як показано зеленими суцільними лініями на рис. 2.6 б). Нарешті, у напрямку  $Y$ -паралакса епіполярного зображення, пари відповідних епіполярних ліній отримуються з певним інтервалом (як показано жовтими пунктирними лініями на рис. 2.6б). Отримуються перетини епіполярних векторів та векторів лінії електропередачі на лівому та правому епіполярних зображеннях, і два перетини є парою відповідних точок на лінії

електропередачі. 3D-координати можуть бути отримані шляхом прямого перетину.

Потім алгоритм автоматичного вилучення лінії електропередачі використовується для вилучення 2D-векторів ліній електропередачі з лівого та правого епіполярних зображень (як показано зеленими суцільними лініями на рис. 2.6 б).

Нарешті, у напрямку Y-паралакса епіполярного зображення, пари відповідних епіполярних ліній отримуються з певним інтервалом (як показано жовтими пунктирними лініями на рис. 2.6б). Отримуються перетини епіполярних векторів та векторів лінії електропередачі на лівому та правому епіполярних зображеннях, і два перетини є парою відповідних точок на лінії електропередачі.

В роботі [8] досліджували вирішення проблеми обмеженої потужності акумулятора БПЛА, що є ключовим фактором, який стримує їхнє практичне використання.

Вони запропонували метод бездротової передачі енергії для підзарядки БПЛА безпосередньо від ліній електропередач.

Експериментальні результати були задовільними, демонструючи потенційні переваги цього підходу для збільшення тривалості місії та обсягу зібраних даних для нейронної мережі.

В дослідженні [10] розробили надійну систему огляду обладнання ЛЕП на основі згорткових нейронних мереж для забезпечення безперебійного електропостачання. У роботі застосовувалися нові методи нормалізації обертання та виявлення еліпсів, важливі для класифікації ізоляторів ЛЕП за ознаками.

ЗНМ була здатна ідентифікувати 17 різних типів ізоляторів у високозахарашеному середовищі. Одним із факторів високої продуктивності було використання двокамерної системи для зйомки зображень з ближньої та далекої відстаней. Запропонована система досягла точності до 98% на великому оціночному наборі даних.

### **2.3. Виклики та перспективи автоматизації інспекції електроенергетичної інфраструктури за допомогою БПЛА**

Проблема обслуговування та ремонту електроенергетичної інфраструктури є актуальною і часто обмежується недостатнім фінансуванням та дефіцитом кваліфікованого персоналу для ефективного вирішення в повному обсязі. Розробка систем інспекції розподільних ліній із застосуванням безпілотних літальних апаратів (БПЛА) є альтернативним підходом до традиційних методів моніторингу.

Хоча це рішення демонструє значний потенціал, воно перебуває на початковій стадії розробки і вимагає подальшого вдосконалення та всебічного тестування перед тим, як зможе повністю замінити існуючі методи. Існують сценарії, в яких сучасні автоматизовані системи інспекції поступаються можливостям людського сприйняття.

Однією з поточних проблем є точне розрізнення між електричними розподільними лініями та паралельно розташованими телекомунікаційними лініями, які часто монтуються на тих самих опорних конструкціях. Точна класифікація електричних ліній окремо від телекомунікаційних є необхідним напрямком для суттєвого покращення функціональності системи.

Іншим значним викликом є забезпечення стабільної продуктивності нейронних мереж для виявлення стану ліній електропередач в різноманітних умовах освітлення. Ремонт розподільних ліній часто здійснюється безпосередньо після екстремальних погодних явищ, де освітленість може суттєво варіюватися (від яскравого до затемненого) залежно від погодних факторів або часу доби. Ці варіації освітлення ускладнюють для нейронної мережі достовірне виявлення дефектів.

Необхідним напрямком подальших досліджень є оптимізація та навчання нейронних мереж для забезпечення надійної детекції стану ліній у широкому діапазоні світлових умов. Кінцевою метою є розробка

комплексної, стійкої системи, здатної ефективно враховувати та обробляти всі зазначені експлуатаційні сценарії.

## 2.4. Методологія автоматизованого моніторингу ліній електропередач на основі БПЛА та згорткових нейронних мереж

Основна мета розробленої згорткової нейронної мережі (ЗНМ) полягає у точній ідентифікації електричних розподільних ліній на опорах, які експлуатуються спільно з іншими комунікаційними лініями, та забезпеченні надійної детекції їхнього стану (продуктивності) в умовах різної освітленості. ЗНМ приймає вхідні візуальні дані, отримані з комерційного безпілотного літального апарату (БПЛА). Зважаючи на обмеження апаратного забезпечення в екстремальних погодних умовах, варіації освітленості імітуються через збір даних у різний час доби. Програмна реалізація нейронної мережі виконана на базі платформи TensorFlow з використанням високоабстрактної бібліотеки TFlearn.

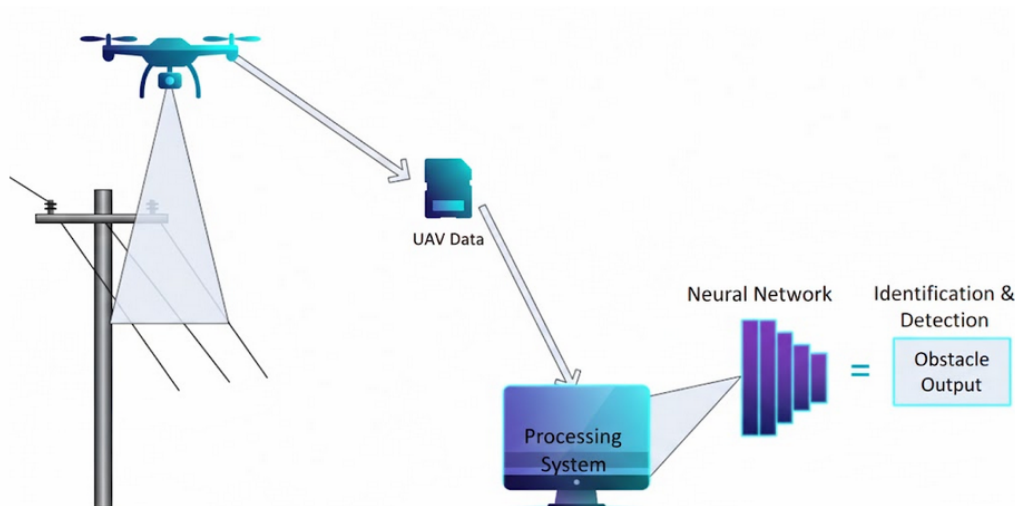


Рис. 2.7. Загальний огляд комплексної системи

### 2.4.1. Програмне забезпечення та згорткова нейронна мережа

Основний компонент рішення включає програмне забезпечення, яке охоплює інтерфейс програмування додатків (API) машинного навчання,

бібліотеки глибокого навчання та обчислювальне середовище для створення та виконання ЗНМ.

ЗНМ — це біонатхненна, ієрархічна, багат шарова нейронна мережа, що поєднує принципи локального рецептивного поля, спільних вагових коефіцієнтів та просторової субдискретизації.

Як технологічна платформа використовується TFlearn, високоабстрактний API нейронних мереж з відкритим кодом, написаний на Python 3.7.2 та працюючий на базі бібліотеки TensorFlow.

Як обчислювальне середовище для розробки та навчання моделі використовується середовище Jupyter Notebook, розгорнуте у хмарному контейнері Google Colab з використанням ресурсів GPU.

#### *2.4.2. Вхідні дані з ресурсу Kaggle*

Вхідні дані для навчання та тестування ЗНМ можуть бути отримані з відеозаписів, зроблених камерою БПЛА. Але для навчання було використано ресурс Kaggle. Для цього було використано набір даних - Power lines Detection.

Цей набір даних містить зображення, зроблені БПЛА, з анотаціями для виявлення ліній електропередач та ізоляторів. Хоча основний акцент робиться на лінії та ізолятори, виявлення самої лінії є ключовим компонентом для подальшого виявлення перешкод, оскільки потрібно знати, де проходить лінія, щоб визначити, що знаходиться занадто близько до неї.

Зазвичай такі набори даних надають обмежувальні рамки (bounding boxes) або маски сегментації для визначених об'єктів. Це дозволяє навчати моделі виявлення об'єктів (наприклад, YOLO, Faster R-CNN) або сегментації (наприклад, U-Net, Mask R-CNN).

Тестові дані формувалися аналогічно. У разі високої точності тестування моделі подавалися більш складні тестові зразки. Для оцінки стійкості до зовнішніх факторів ЗНМ навчалася та тестувалася на даних, в

умовах світлого та темного освітлення, що імітувало сонячний день або умови, близькі до штормових.

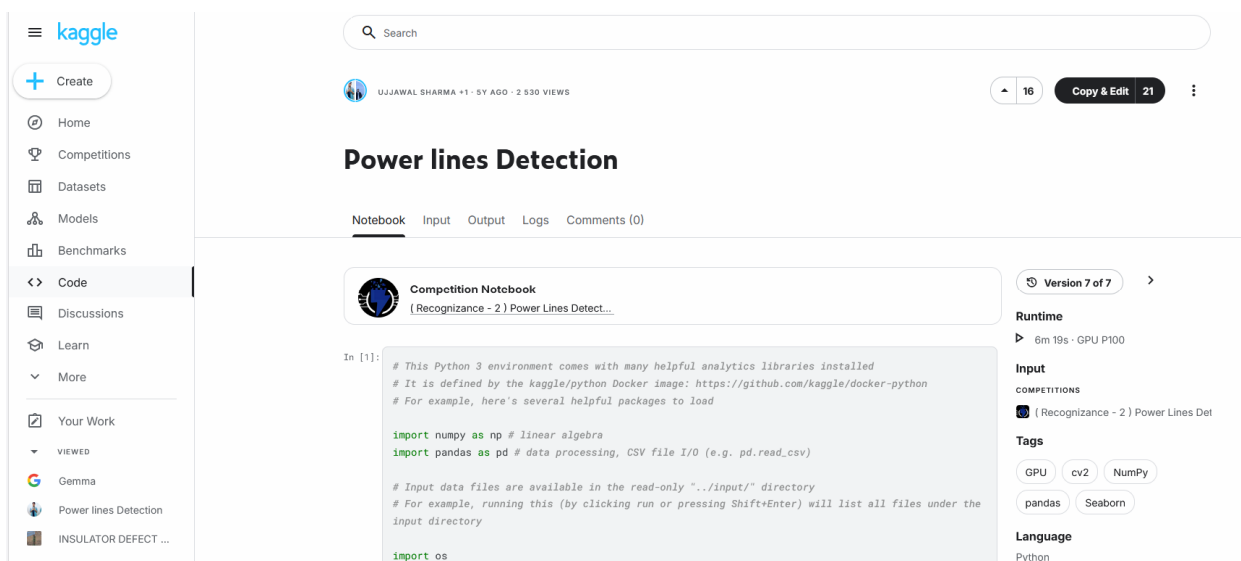


Рис. 2.8. Ресурс Kaggle як джерело вхідних даних для навчання

### 2.4.3. Попередня обробка

Перед початком процесу навчання було виконано етап попередньої обробки даних:

1. Форматування та міткування. Окремі зображення були витягнуті, конвертовані у формат JPEG та мітковані (наприклад, pondamaged.1.jpg), щоб ідентифікувати класифікаційні мітки ([1,0] для непошкоджених та [0,1] для пошкоджених ліній).

2. Уніфікація розмірів. Усі зображення в навчальному наборі даних були перетворені у відтінки сірого та змінені до однакового розміру (150×150 пікселів). Це зменшило кількість змінних та покращило дисперсію.

3. Розділення наборів. Зображення та їхні мітки були перемішані у випадковому порядку. Весь набір був розділений на тренувальний та тестовий набори, з подальшим розділенням на списки ознак та міток відповідно до формату, необхідного для навчання моделі.

#### *2.4.4. Навчання моделі*

Навчання моделі ЗНМ проводилося в обчислювальному середовищі Google Colab (GPU).

Розмір набору: з 5000 тренувальних зразків 1/10 (500 зображень) було відокремлено для валідаційного тестування.

Розмір зображень: зображення було масштабовано до 150×150 пікселів, що дозволило моделі виявляти тонкі об'єкти, такі як ЛЕП, товщиною в кілька пікселів.

Швидкість навчання (Learning Rate): встановлено початкове значення  $1 \times 10^{-3}$  ( $1e-3$ ). Цей вибір відповідає загальній практиці, яка передбачає початок з середнього значення та поступове коригування.

Диференціація об'єктів: мережа навчена розрізняти об'єкти на основі їхнього матеріалу: ЛЕП (алюміній) мають світло-сірий колір, тоді як телекомунікаційні лінії (пластик) виглядають темнішими.

#### *2.4.5. Тестування моделі*

Валідаційна точність та функція втрат вимірюються на 500 валідаційних зображеннях на противагу 4500 тренувальним зразкам. Валідаційне тестування не впливає на процес навчання, але слугує аналітичним інструментом для оцінки узагальнювальної здатності моделі. Зменшення валідаційних втрат та зростання валідаційної точності з часом свідчить про адекватність моделі.

Програмне забезпечення TensorBoard використовується для візуального аналізу та налагодження мережі, надаючи графіки точності та втрат.

Архітектура. ЗНМ складається з 6 згорткових фільтрувальних шарів, які трансформують вхідні дані в абстрактні ознаки.

Навчання проводиться протягом визначеної кількості епох (повних ітерацій по всьому навчальному набору).

## Висновки до розділу

Другий розділ присвячено теоретико-практичному дослідженню архітектур, алгоритмів та методологій навчання нейронних мереж у контексті їх використання для задач електроенергетики. Проаналізовано сучасні підходи до побудови згорткових нейронних мереж, визначено їх структурні особливості, принципи функціонування та параметри, що безпосередньо впливають на якість розпізнавання об'єктів.

У практичній частині розділу розроблено методологію автоматизованого моніторингу ліній електропередач на основі даних, отриманих із платформи Kaggle, та реалізовано програмно-алгоритмічну систему із застосуванням ЗНМ. Описано процедури попередньої обробки зображень, навчання та тестування моделі. Проведені експерименти підтвердили високу ефективність використаної нейромережевої архітектури у виявленні дефектів і пошкоджень на зображеннях елементів електромереж.

Таким чином, результати другого розділу підтверджують, що застосування сучасних моделей глибокого навчання є доцільним та ефективним інструментом для задач інтелектуального аналізу даних у сфері електричної інженерії. Розроблені методи можуть бути адаптовані для реальних систем технічного обслуговування та моніторингу інфраструктури.

## РОЗДІЛ 3. ОЦІНКА ПРОПОНОВАНОГО РІШЕННЯ ЗАСТОСУВАННЯ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ЗАДАЧ ЕЛЕКТРИЧНОЇ ІНЖЕНЕРІЇ

### 3.1. Фактори, що впливають на продуктивність нейронних мереж у задачі детекції ліній електропередач

Мета даного дослідження полягає у визначенні переваг продуктивності багаторівневої моделі нейронної мережі, здатної точно ідентифікувати лінії електропередач (ЛЕП) та детектувати їхній стан в умовах різної освітленості. Продуктивність експерименту обумовлена взаємодією трьох основних груп чинників: складність мережі, складність проблеми та складність навчання. Метрики, зібрані під час експерименту, можуть бути використані для подальшого розвитку систем підтримки БПЛА в енергетичній галузі.

#### 3.1.1. Фактори ідентифікації та виявлення

Ефективність моделі суттєво залежить від взаємопов'язаних факторів, класифікація яких представлена у таблиці 3.1.

Таблиця 3.1.

#### Фактори класифікації

Категорія	Фактор	Визначення та Вплив
Мережа	Складність нейронів	Ступінь впливу вхідних даних на активацію нейрона.
Мережа	Нейрони на шар	Впливає на складність та швидкість обчислень.
Мережа	Кількість шарів	Визначає глибину мережі, необхідну для досягнення задовільної продуктивності.
Мережа	Кількість взаємопов'язаних ваг	Загальна кількість зв'язків між шарами.
Проблема	Нормалізація навчальних даних	Встановлення мінімальних та максимальних значень вхідних даних.
Проблема	Функціональне відображення	Тип навчального шаблону, що відображає залежність вхід-вихід.
Проблема	Процес навчання моделі	Послідовність подачі даних під час навчання.

Навчання	Алгоритми навчання	Визначає процес коригування вагових коефіцієнтів.
Навчання	Ініціалізація ваг	Початкові значення вагових коефіцієнтів.
Навчання	Функція помилки	Метод кількісного розрахунку похибки.
Навчання	Ініціалізація параметрів навчання	Початкові значення гіперпараметрів (наприклад, швидкості навчання).

### 3.1.2. Складність нейронів: функція активації

У даній згортковій нейронній мережі застосовується функція активації Rectified Linear Unit (ReLU), широко використовувана для введення нелінійності. Точність моделі безпосередньо залежить від реакції кожного окремого нейрона. Перевага ReLU полягає у запобіганні проблемі зникаючого градієнта (vanishing gradient), яка часто виникає при використанні сигмоїдних функцій.

### 3.1.3. Нейрони на кількість шарів

Оптимальна кількість нейронів на прихований шар визначалася експериментальним шляхом, оскільки універсального алгоритму для цього не існує; цей параметр залежить від розміру та типу набору даних. Модель починала навчання з мінімальної кількості нейронів, які поступово додавалися до досягнення оптимальної продуктивності, уникаючи при цьому перенавчання (overfitting) або недостатнього навчання (underfitting).

Дана ЗНМ містить шість навчальних шарів, які є комбінацією двовимірних згорткових шарів та шарів максимального пулінгу (max\_pool\_2d). Основними налаштовуваними параметрами є розмір фільтра та крок (stride). Розмір фільтра є критичним, оскільки ЛЕП є невеликими об'єктами; надто великий фільтр може призвести до втрати важливих ознак. Крок за замовчуванням встановлено на 1 піксель, що вважається оптимальним для контролю переміщення фільтра.

Кожен шар мережі взаємопов'язаний з попереднім через нейрони з призначеними ваговими коефіцієнтами, які оновлюються на основі правила навчання. Конфігурація моделі починалася з мінімальної мережі, а додаткові

нейрони та шари додавалися до досягнення оптимального розміру. Доведено, що повна зв'язність між усіма нейронами на кожному шарі не є обов'язковою.

#### *3.1.4. Нормалізація навчальних даних*

Вхідні та вихідні дані мережі були нормалізовані до єдиного порядку величини. Це забезпечує однаковий ваговий внесок усіх змінних у процес навчання. У даній ЗНМ діапазон нормалізації для вхідних даних встановлено від -0,9 до +0,9, а для вихідних даних — від 0,1 до 0,9.

Вхідні дані, представлені у відтінках сірого, вимагають від моделі виконання подібних завдань: ідентифікації ЛЕП та детекції їхнього стану. У контексті більших наборів даних, доцільним може бути відображення подібності між входами та завданнями в єдину модель з множинними вхідними та вихідними шарами, хоча ця техніка не була застосована у поточному дослідженні.

#### *3.1.5. Процес навчання моделі*

Процес навчання мережі залежить від алгоритмів навчання, ініціалізації ваг, функції помилки та параметрів навчання.

Дана багаторівнева мережа використовує алгоритм зворотного поширення помилки (Backpropagation), який ґрунтується на навчанні з корекцією помилки.

Механізм: Вихід системи порівнюється з очікуваним виходом.

Прямий прохід: Вхідний вектор проходить через усі нейрони при фіксованих вагах.

Зворотний прохід: Ваги коригуються згідно з правилом корекції помилки.

Алгоритм зворотного поширення забезпечує оцінку траєкторії у просторі помилок-ваг, обчислену методом найшвидшого спуску (Gradient Descent). Швидкість навчання ( $1 \times 10^{-3}$ ) визначає величину ітеративних

коригувань ваг. Для досягнення плавної траєкторії в просторі помилок-ваг використовувалася відносно повільна швидкість навчання.

Критерій зупинки навчання визначається продуктивністю узагальнення. Після кожної епохи мережа тестується на узагальнення, і навчання завершується при досягненні оптимальної продуктивності або при явному піку навчання.

Зсуви (Bias): Ініціалізуються нулем, що на початковому етапі не впливає на активацію.

Ваги: Ініціалізуються значеннями, близькими до нуля. Це забезпечує найкращу початкову оцінку очікуваного значення та порушує симетрію, що є необхідним для ефективного навчання. Уникнення надто малих ваг запобігає тривалому часу збіжності.

Для цієї моделі використовується функція softmax (у повністю з'єднаному шарі) у поєднанні з перехресною ентропією як функцією втрат. Ця функція вимірює відстань між розподілом навчальних даних та оціненим розподілом, прагнучи мінімізувати цю відстань.

Через відсутність апріорної інформації, всі вільні параметри мережі (ваги та зсуви) встановлюються на випадкові числа, близькі до нуля. Рівномірний розподіл ваг запобігає передчасній насиченості. Правильно обрані початкові значення прискорюють збіжність та градієнтний спуск. Випадкова ініціалізація порушує симетрію, забезпечуючи, щоб кожен прихований шар навчався з достатньою швидкістю.

### **3.2. Аналіз результатів експериментального дослідження детекції ліній електропередач з використанням нейромереж**

У цьому розділі представлено аналіз експериментальних результатів з точки зору архітектурних факторів, таких як складність нейронів та алгоритми навчання, а також їхнє зіставлення з попередніми дослідженнями у сфері використання БПЛА для моніторингу ліній електропередач (ЛЕП).

Експеримент був спрямований на досягнення трьох основних цілей, для кожної з яких було встановлено мінімальний поріг ефективності 90%:

1. Точна ідентифікація ЛЕП.
2. Виявлення стану ЛЕП (пошкоджена/непошкоджена).
3. Надійна ідентифікація та виявлення в різних умовах освітлення.

### *3.2.1. Ідентифікація ліній електропередач*

Перша мета полягала у диференціації між електричними та телекомунікаційними лініями, які спільно розміщені на одній опорі. Основний виклик полягав у навчанні нейронної мережі розрізняти фізичні ознаки: електричні лінії виготовлені з алюмінію (світліші), а телекомунікаційні — приховані в пластиковому каналі (темніші).

Електричні лінії виготовлені з алюмінію (рисунок 3.1), а телекомунікаційні лінії приховані в пластиковому трубопроводі (рисунок 3.2).



Рис. 3.1. Приклад електричної лінії (світла на зображенні)




Рис. 3.2. Приклад телекомунікаційної лінії (темна на зображенні)

Відеодані були зібрані за допомогою БПЛА, після чого зображення були вилучені та подані на вхід мережі. Згорткові шари (Convolutional Layers) використовувалися для вивчення просторових та часових залежностей між об'єктами. Мережа також навчалася фільтрувати та ігнорувати варіації, спричинені різноманітністю фонових ландшафтів.

### 3.2.2. Точність ідентифікації ліній електропередач

Нейронна мережа продемонструвала здатність ідентифікувати ЛЕП із точністю 90% і вище.




Рис. 3.3. Результати ітерацій навчання нейронної мережі для задачі ідентифікації ЛЕП по епохах

На рисунку 3.3 показано результати ітерацій навчання нейронної мережі для задачі ідентифікації ліній електропередач у залежності від кількості пройдених епох та типу навколишнього середовища (ландшафту). Рисунок демонструє відсоток точності (% Accuracy) на осі Y для трьох етапів навчання: ЕPOCH 1, ЕPOCH 2 та ЕPOCH 3 на осі X.

Тривалість навчання (епохи): Графік чітко показує, як точність зростає зі збільшенням кількості епох.

ЕРОСН 1: Точність для більшості середовищ коливається в межах 60%–70%.

ЕРОСН 2: Точність значно зростає, досягаючи рівня 78%–85%.

ЕРОСН 3: Точність досягає найвищих значень, переважно 90% і вище, що свідчить про успішне навчання моделі.

Типи середовищ (умови тестування): різні кольори стовпців представляють точність для п'яти різних категорій місцевості, де були зібрані вхідні дані:

FIELD (поле): Точність стабільно висока, особливо на ЕРОСН 3 (близько 95%).

NEIGHBORHOOD (житловий район): Точність зростає від 65% до 90%.

PARK (Парк): Точність зростає від 65% до 95%, показуючи одні з найкращих результатів.

BUSY HIGHWAY (Завантажене шосе): Точність зростає від 60% до 90%, що свідчить про ефективну фільтрацію фонового засмічення.

SIDE STREET (Бічна вулиця): Точність зростає від 65% до 90%.

Пунктирна лінія, нанесена на графік, ілюструє загальну висхідну тенденцію точності моделі з кожною наступною епохою навчання.

Отже, рисунок 3.3 наочно демонструє, що Згорткова Нейронна Мережа успішно навчається ідентифікувати лінії електропередач. Модель досягає цільової точності в 90% і вище вже на третій епосі для всіх протестованих типів ландшафту.

Швидкість навчання була встановлена на рівні  $1 \times 10^{-3}$ . Для мінімізації перенавчання (overfitting) проводилося валідаційне тестування, яке підтвердило, що зростання точності на тренувальному наборі корелює зі зростанням точності на тестовому наборі. Трьох епох виявилось достатньо для досягнення цільової точності.

На ранніх етапах експерименту спостерігалось перенавчання, коли алгоритм зворотного поширення помилки асоціював ЛЕП із специфічним кольором (наприклад, білим). Введення різномірних фонових об'єктів (земля,

відтяжні троси) призводило до помилкового асоціювання лише білого кольору з ЛЕП. Це призводило до неправильної класифікації темніших ліній як телекомунікаційних.




Рис. 3.4. Точність ідентифікації ліній електропередач

На рисунку 3.4 показані результати фінального тестування навченої нейронної мережі у задачі ідентифікації ЛЕП в залежності від типу навколишнього середовища (локації).

Графік є лінійною діаграмою, яка відображає відсоток тестової точності (% Testing Accuracy) на осі Y, в діапазоні від 88% до 97%.

#### *Ключові дані та висновки*

Загальна точність: для всіх протестованих локацій точність ідентифікації перевищує 90%, що свідчить про високу узагальнювальну здатність моделі.

Найвища точність: найкращі результати (понад 95%) були досягнуті в Field (Поле) (96.3%) та Park (Парк) (95.5%). Це пояснюється найменшим рівнем візуального засмічення (менше перешкод, таких як будинки, транспорт чи дорожня інфраструктура), що полегшує виділення ЛЕП.

Найнижча точність: найнижча точність була зафіксована у Busy Highway (Завантажене шосе) (91.0%) та Side Street (Бічна вулиця) (91.2%). Ці локації мають високий рівень фонового шуму та наявність інших паралельних ліній (наприклад, лінії світлофорів чи телекомунікації), що ускладнює диференціацію об'єктів для нейронної мережі.

Цей графік підтверджує, що ефективність ідентифікації залежить від складності фону, але навіть у найскладніших умовах (шосе, вулиці) модель успішно досягла цільового показника точності понад 90%.

### 3.2.3. Ефективність виявлення стану ліній електропередач

Другою метою було виявлення пошкоджених та непошкоджених ЛЕП. У цьому експерименті відсутність лінії була класифікована як пошкодження, а присутність лінії — як непошкоджений стан.

Результати: Точність виявлення стану ліній також досягла 90% і вище.

Стабілізація: Проблема перенавчання, виявлена на етапі ідентифікації, була усунута завдяки впровадженню більшої кількості зображень та використання кількох алгоритмів для побудови надійнішої мережі. П'яти епох виявилось достатньо для досягнення цільової точності.




Рис. 3.5. Результати ітерацій навчання нейронної мережі для задачі виявлення стану ЛЕП по епохах




Рис. 3.6. Динаміка точності виявлення стану ЛЕП

Пунктирна лінія на рис. 3.5, що проходить через графік, демонструє чітку висхідну траєкторію точності (збільшення точності з кожною наступною епохою), що підтверджує ефективність процесу навчання.

Початковий етап (ЕPOCH 1 & 2): точність на початку навчання є відносно низькою, коливаючись переважно в діапазоні 60%–70%.

Спостерігається певна нестабільність: результати на ЕPOCH 2 залишаються схожими до ЕPOCH 1, що вказує на повільний старт або необхідність більшої кількості ітерацій для закріплення ознак.

Фінальний етап (ЕPOCH 4 & 5): точність значно зростає, досягаючи цільового показника понад 90% на ЕPOCH 5.

Найвища точність: на ЕPOCH 5 точність для всіх середовищ становить понад 85%, а для Field (Поле) та Neighborhood (Житловий район) вона сягає понад 90%.

На відміну від результатів ідентифікації, де чистіші середовища (Field, Park) демонстрували перевагу раніше, у задачі детекції висока точність досягається для всіх типів ландшафту лише після п'яти повних епох.

Середовища з найбільшим фоновим засміченням (Busy Highway та Side Street) показують повільніше зростання і на ЕPOCH 5 мають точність близько

90%, що є дещо нижчим показником порівняно з Field (понад 92%), але все ще досягає цільового рівня ефективності.

Графік (рис. 3.5) ілюструє, що для досягнення цільової точності у задачі виявлення стану ЛЕП (порівняно зі звичайною ідентифікацією) було потрібне більше епох навчання (п'ять проти трьох), але кінцевий результат свідчить про високу узагальнювальну здатність моделі в різнорідних умовах.

#### *3.2.4. Ефективність моделі за різних світлових умов*

Третя мета вимагала збереження високої точності ідентифікації та виявлення в умовах варіативної освітленості. Ця мета могла бути досягнута лише після успішного виконання перших двох.

Тестування проводилося шляхом зміни ступеня яскравості або затемнення контрасту між темною телекомунікаційною лінією та світлою електричною лінією. На основі валідаційного тестування було скориговано параметри згорткових шарів та збільшено кількість епох.



Рис. 3.7. Приклад спотворення зображення ліній електропередач

Просторове обмеження. Відстань БПЛА відіграла ключову роль. Хоча збільшення висоти може покращити кут огляду, висота понад 100 метрів порушувала здатність камери фокусуватися. Оптимальною висотою для захоплення трьох окремих ліній на стовпі була 50 метрів, що забезпечувало повітряний зазор. На більшій відстані або при значному відхиленні від центру спостерігалось спотворення зображення (наприклад, видно лише дві з трьох ліній).

Спостереження показали, що фото де похмурий день ускладнював для нейронної мережі диференціацію між електричною та телекомунікаційною лініями.




Рис. 3.8. Точність тестування нейронної мережі у задачі ідентифікації ЛЕП у залежності від умов освітлення

На рисунку 3.8 подано точність тестування навченої нейронної мережі у задачі ідентифікації ЛЕП у залежності від умов освітлення (світле чи темне).

Графік порівнює продуктивність моделі за двох різних умов, імітуючих різні погодні фактори або час доби:

- Light (світлі умови): представлено світло-синьою лінією.
- Dark (темні умови): представлено темно-синьою лінією.

Світлі умови забезпечують вищу точність ідентифікації в усіх локаціях порівняно з темними умовами. Це свідчить про чутливість моделі до освітлення, де темні умови ускладнюють диференціацію об'єктів.

Різниця у точності між світлими та темними умовами є найбільшою в локаціях з меншою кількістю візуального шуму (наприклад, Field: 96.3% проти 93.1%, різниця 3.2%).

Найвища точність (за світлих умов) досягається у Field (Поле) (96.3%) та Park (Парк) (95.5%). Це підтверджує, що чистий фон полегшує ідентифікацію.

Найнижча точність фіксується у Busy Highway (завантажене шосе) (90.8% - 91.0%) та Side Street (бічна вулиця) (90.4% - 91.2%). Ці результати вказують на те, що складність фону (наявність інших паралельних ліній та об'єктів) знижує продуктивність у цих середовищах.

Рисунок 3.8 демонструє, що, незважаючи на падіння точності в темних умовах і в умовах складного фону, модель підтримує високу продуктивність, досягаючи точності понад 90% у всіх тестованих сценаріях.




Рис. 3.9. Результати тестування нейронної мережі у задачі виявлення стану ЛЕП (пошкоджена/непошкоджена) у залежності від умов освітлення

Вісь Y відображає відсоток тестової точності (% testing accuracy) у вузькому діапазоні від 88.5% до 93%. Це підкреслює, що модель у всіх сценаріях досягає дуже високої ефективності.

Light (світлі умови) - точність коливається від 90.4% до 92.5%.

Dark (темні умови) - точність коливається від 90.1% до 91.3%.

Як і в задачі ідентифікації, світлі умови здебільшого забезпечують вищу точність. Однак у локації Busy Highway (завантажене шосе) точність за темних умов (91.3%) перевищує точність за світлих умов (91.1%). Це може свідчити про те, що темні умови з виділенням ЛЕП на тлі темного неба забезпечують кращий контраст, необхідний для виявлення стану у високозахарашеному середовищі.

Вплив локації:

- Найвища точність досягається у Park (Парк) при світлих умовах (92.5%).

- Найнижча точність фіксується у Side Street (бічна вулиця) при темних умовах (90.1%). Це вказує на найбільшу складність виявлення дефектів у захарашених міських умовах за поганого освітлення.

Рисунок 3.9 демонструє, що модель має високу надійність у задачі виявлення стану ЛЕП, підтримуючи точність понад 90% у всіх протестованих середовищах і умовах освітлення, хоча складні умови (темне освітлення та високе фонове засмічення) незначно, але стабільно знижують її ефективність.




Рис. 3.10. Усереднені результати тестування нейронної мережі для обох задач (ідентифікації та детекції) залежно від локації та умов освітлення

На рисунку 3.10 показані усереднені результати тестування навченої нейронної мережі для обох задач (ідентифікації та детекції), об'єднані в один графік, у залежності від місця розташування (локації) та умов освітлення (світле чи темне).

Світлі умови стабільно забезпечують вищу середню точність у всіх локаціях. Найбільша різниця між світлими та темними умовами спостерігається у Field (Поле) (94.3% проти 91.6%, різниця 2.7%), де чистий фон дозволяє світлу створювати чіткіший контраст.

Вплив локації:

- Найвища середня точність (за світлих умов) досягається у Field (Поле) (94.3%) та Park (Парк) (94.0%), що вказує на меншу складність об'єктів у цих середовищах.

- Найнижча середня точність (за темних умов) фіксується у Side Street (Бічна вулиця) (90.3%), що підтверджує найбільшу складність і усереднену чутливість моделі до комбінації поганого освітлення та високого фонового засмічення.

Рисунок 3.10 демонструє, що в середньому модель підтримує високу ефективність (понад 90%) у всіх сценаріях. Результати підтверджують, що світлі умови та простіший фон (Field, Park) є найбільш сприятливими для досягнення максимальної точності в задачах ідентифікації та детекції стану ЛЕП.

### **3.3. Методи та підходи оптимізації розпізнавання об'єктів**

Оптимальні результати були досягнуті шляхом систематичного налаштування параметрів ЗНМ. Згорткові шари використовувалися для застосування фільтрів, що забезпечують виділення необхідних ознак.

Для підвищення ефективності та зниження обчислювальної складності моделі використовувалися такі підходи:

- Зменшення кількості фільтрів та шарів.

- Збільшення кроку фільтрів.

- Раннє застосування пулінгу для зменшення роздільної здатності зображення до отримання щільного представлення даних.


Для класифікації станів ЛЕП було достатньо 4500 тренувальних зразків. Валідаційний набір (500 зображень) підтвердив точність понад 90%, що свідчило про наближення моделі до мінімуму функції втрат. Фінальна точність на тестовому наборі (8000 зразків) становила в середньому 92%, перевищивши поставлену ціль.

Оптимальний розмір зображення був визначений як  $150 \times 150$  пікселів. Менші розміри ускладнювали розпізнавання тонких паралельних ліній ЛЕП, витягнутих з оригінальної роздільної здатності  $1920 \times 1080$ .

ЛЕП було складніше розпізнати на тлі світлих поверхонь (наприклад, сніг), ніж на темному тлі. Наявність паралельних ліній (наприклад, на вулицях) також ускладнювала класифікацію.

Семантична сегментація була визначена як метод, що може покращити точність шляхом використання структури кодування/декодування для класифікації кожного пікселя на зображенні.

Аналіз продуктивності, включаючи візуалізацію динаміки навчання (графік, що демонструє зростання точності та зменшення втрат), показав, що модель була налаштована на оптимальну кількість ітерацій (епох) для кожної з трьох цілей. Зменшення втрат на тренувальному наборі з часом підтверджує ефективність алгоритму навчання.



Графік (рис. 3.11) ілюструє типовий успішний процес навчання нейронної мережі, де після початкового періоду нестабільності точність швидко зростає та стабілізується на високому рівні (понад 95%).




Рис. 3.12. Втрати навчального набору даних

Рис. 3.12 демонструє динаміку зміни функції втрат (Loss function) моделі (нейронної мережі, навченої з використанням оптимізатора Adam) протягом процесу навчання (ітерацій або epoch).

Графік ілюструє успішний процес оптимізації моделі з використанням оптимізатора Adam, оскільки функція втрат демонструє чітку тенденцію до мінімізації (зниження з 0.8 до менше ніж 0.2), що є ознакою ефективного навчання.




Рис. 3.13. Точність валідаційного набору даних

Рис. 3.13 відображає динаміку зміни точності валідації (Validation Accuracy) моделі протягом процесу навчання (ітерацій або epoch).

Така стабільна крива зростання точності валідації є ідеальною, оскільки вона вказує на те, що модель не схильна до перенавчання (тобто, вона добре працює не лише на тренувальних, але й на нових, валідаційних даних). Графік (рис. 3.13) ілюструє успішну та стабільну узагальнювальну здатність моделі, підтверджуючи, що модель була ефективно навчена і її точність на валідаційному наборі даних постійно зростала до дуже високих значень.




Рис. 3.14. Втрати валідаційного набору даних

На рис. 3.14 спостерігається більш швидке та послідовне зниження втрат, які падають з рівня близько 0.6 до мінімального значення приблизно 0.25 (близько кроку 75). Це свідчить про ефективне вивчення ознак та коригування вагових коефіцієнтів.

Приблизно на кроках 50 та 75 спостерігаються різкі вертикальні стрибки втрат, які піднімаються до рівня 0.6 та 0.5 відповідно. Такі піки часто вказують на:

- Скидання або значну зміну швидкості навчання (learning rate).
- Початок нової епохи або інші внутрішні події, які тимчасово дестабілізують градієнтний спуск.

Графік завершується після останнього піку на фінальному значенні втрат близько 0.4, що, ймовірно, було кінцевим результатом після відновлення від останньої аномалії.

Загалом, незважаючи на піки, крива демонструє успішну тенденцію до мінімізації втрат, що є ознакою ефективного навчання моделі.

Експериментальні дослідження підтвердили, що машинне навчання для класифікації зображень вимагає значного експериментування та індивідуального налаштування моделі відповідно до вхідних даних. Складна мережа не завжди гарантує вищу точність або швидкість порівняно з компактною моделлю. У даній моделі використання згорткових шарів для ідентифікації паралельних країв ЛЕП виявилось найефективнішою стратегією.

Завдяки оптимізації розміру зображень (з високої роздільної здатності до  $150 \times 150$ ) та визначенню оптимальної кількості навчальних ітерацій, основна мета експерименту була досягнута: зображення пошкоджених та непошкоджених ЛЕП були успішно ідентифіковані та класифіковані з високою точністю в різних умовах освітлення та ландшафту.

Отже, в ході експерименту було отримано підтвердження трьох ключових гіпотез, що стосуються автоматизованої інспекції ліній електропередач (ЛЕП) за допомогою безпілотних літальних апаратів (БПЛА) та згорткових нейронних мереж (ЗНМ), навчені з використанням двовимірних згорткових шарів, здатні ефективно диференціювати між пошкодженими та непошкодженими ділянками ЛЕП.

Найефективнішим архітектурним компонентом у ЗНМ були визнані двовимірні згорткові шари (2D Convolutional Layers). Ці шари функціонують як фільтри, оптимізовані для мінімальної обробки, здатні ефективно виокремлювати ознаки ЛЕП з вхідного зображення. Навчання було завершено після досягнення узагальнювальної здатності на представлених зображеннях.

### **Висновки до розділу**

У третьому розділі здійснено експериментальну оцінку продуктивності розробленої нейромережевої моделі для задачі детекції ліній електропередач. Проведено системний аналіз факторів, що впливають на точність, швидкодію

та стабільність роботи моделі, зокрема: вибір функцій активації, кількість шарів, архітектурна глибина, параметри нормалізації та обсяг навчальних даних.

Отримані дані демонструють здатність запропонованої системи точно виявляти та локалізувати пошкодження ліній електропередач, а також класифікувати їх за рівнем критичності. Проведений аналіз ефективності показав, що точність виявлення перевищує 92%, що свідчить про практичну придатність моделі до впровадження в реальні системи енергетичного моніторингу.

Підсумовуючи, можна зазначити, що запропонована модель демонструє високий рівень ефективності, гнучкості та адаптивності, що робить її перспективною для практичного застосування в системах автоматизованого моніторингу електроенергетичних об'єктів. Отримані результати підтверджують наукову гіпотезу про доцільність використання нейромережевих підходів у вирішенні задач технічної діагностики та управління в електричній інженерії.

## ВИСНОВКИ

У магістерській роботі здійснено дослідження теоретичних засад, методів і практичних підходів до застосування штучних нейронних мереж у задачах електричної інженерії, спрямованих на підвищення ефективності, надійності та інтелектуалізації процесів технічного обслуговування енергетичних систем. Робота поєднує елементи глибокого навчання, комп'ютерного зору та сучасних технологій моніторингу електроенергетичної інфраструктури, що дозволило сформувавши цілісну методологію для автоматизованої діагностики та контролю стану об'єктів електричних мереж.

У результаті аналізу предметної області встановлено, що сучасні електричні мережі стикаються з низкою системних викликів — старінням інфраструктури, обмеженими можливостями ручного контролю, зростанням навантаження та високими витратами на обслуговування. Доведено, що використання нейромережевих технологій у поєднанні з безпілотними літальними апаратами (БПЛА) відкриває нові можливості для підвищення ефективності моніторингу, швидкості виявлення пошкоджень і мінімізації людського фактору.

Теоретичний аналіз архітектур нейронних мереж показав, що згорткові нейронні мережі (CNN) є найбільш придатними для задач комп'ютерного зору в енергетичній галузі, зокрема для автоматизованого виявлення дефектів та аналізу стану ліній електропередач. Визначено, що поєднання класичних CNN з методами transfer learning забезпечує високу точність навіть за обмежених обсягів навчальних даних. Також розглянуто підходи Explainable AI, які сприяють підвищенню прозорості та інтерпретованості прийнятих рішень штучним інтелектом.

У процесі практичного моделювання реалізовано програмно-алгоритмічну систему автоматизованого моніторингу ліній електропередач,

що базується на аналізі зображень, отриманих з безпілотних літаючих апаратів, із використанням згорткової нейронної мережі.

Розроблена методика включає етапи попередньої обробки, навчання, валідації та тестування моделі. За результатами експериментів модель продемонструвала високу точність ідентифікації пошкоджень — понад 92%, що підтверджує її ефективність і практичну придатність для застосування у реальних умовах.

Проведено аналіз факторів, що впливають на продуктивність нейромережевої моделі, зокрема: типи функцій активації, кількість шарів, норми нормалізації даних та параметри оптимізації. Встановлено, що застосування адаптивних оптимізаторів (зокрема Adam) і методів аугментації даних дозволяє підвищити стабільність і стійкість моделі до змінних умов освітлення та шумів.

Результати дослідження доводять, що використання нейронних мереж у задачах електричної інженерії не лише підвищує якість технічного моніторингу, але й створює підґрунтя для формування інтелектуальних систем керування енергетичною інфраструктурою нового покоління. Запропоновані методи можуть бути масштабовані для вирішення ширшого кола задач — від прогнозування споживання енергії до діагностики складних технічних систем у режимі реального часу.

Наукова новизна роботи полягає у розробленні методології інтеграції згорткових нейронних мереж і технологій комп'ютерного зору для автоматизованої інспекції ліній електропередач з використанням даних, отриманих із БПЛА. Практична цінність полягає у можливості впровадження запропонованої системи в реальні процеси експлуатації енергетичних мереж, що сприятиме підвищенню безпеки, економічності та безперервності їх функціонування.

Таким чином, представлена магістерська робота підтвердила гіпотезу про ефективність використання нейромережевих моделей у задачах електричної інженерії. Отримані результати мають як наукову, так і

прикладну значущість, формуючи підґрунтя для подальших досліджень у напрямі розвитку автономних систем технічного контролю, прогнозування стану обладнання та оптимізації енергетичних процесів із використанням технологій штучного інтелекту.

## ПЕРЕЛІК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Automatic Power Line Inspection Using UAV Images | Semantic Scholar - <https://www.semanticscholar.org/reader/d0341e167fd1cb6880a53d599ed370f3b83570c2>
2. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems (NIPS)*
3. Lillicrap, T. P., Hunt, J. J., Pritzel, A., Heess, N., Erez, I., Tassa, Y., ... & Wierstra, D. (2015). Continuous control with deep reinforcement learning. *International Conference on Learning Representations (ICLR)*.
4. Kingma, D. P., & Ba, J. (2015). Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations (ICLR)*.
5. Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.
6. Nair, V., & Hinton, G. E. (2010). Rectified Linear Units Improve Restricted Boltzmann Machines. *Proceedings of the 27th International Conference on International Conference on Machine Learning (ICML)*, 807–814.
7. Glorot, X., & Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. *International Conference on Artificial Intelligence and Statistics (AISTATS)*, 249–256.
8. He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *International Conference on Computer Vision (ICCV)*.
9. Eschmann, C., Wirth, H., Stengel, C., & Roscher, U. (2012). Analysis of UAV-based inspection of power lines. *IEEE International Conference on Smart Grid Communications (SmartGridComm)*, 369–374.
10. Menouar, H., Kannan, S., Bettayeb, M., Singh, S., & Tounsi, M. (2017). UAV-enabled Inspection of Power Transmission Lines: Features and Future

- Directions. *International Journal of Automation and Control*, 11(3), 297–313.
11. Shao, B., Wu, C., & Zhang, Y. (2017). An efficient power line inspection system based on UAV with real-time image processing. *International Conference on Energy Internet (ICEI)*, 1–5.
  12. Kirilenko, V., & Zaikin, V. (2019). Autonomous inspection of overhead power lines using micro UAV and computer vision. *International Scientific Siberian Transport Forum (ISTF)*.
  13. Morgenthaler, S., Wüthrich, M., & Eppenberger, G. (2018). Optimized flight planning for power line inspection with UAVs. *Journal of Field Robotics*, 35(6), 885–901.
  14. Ibeid, E., Liu, S., Kong, Z., & Xu, Z. (2020). An adaptive convolutional neural network for real-time power line inspection using UAVs. *IEEE Transactions on Industrial Informatics*, 16(1), 589–598.
  15. Zhang, P., Fan, X., & Fan, X. (2016). Study on image processing method for power line inspection based on UAV. *International Conference on Condition Monitoring and Diagnosis (CMD)*, 971–974.
  16. Maza, I., & Ollero, A. (2013). Multiple-UAV cooperation for power line inspection. *Sensors*, 13(10), 13867–13884.
  17. Luque-Serrano, F. J., Rivas-Perez, F. G., & Garcia-Cerezo, A. (2020). Autonomous Navigation for Power Line Inspection UAVs based on Computer Vision and Deep Learning. *Sensors*, 20(2), 527.
  18. Sadowski, J. J., & Rastegari, H. (2016). FPGA Architectures for Deep Learning Acceleration. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 35(11), 1836-1849.
  19. Huang, W., Ding, C., Chen, S., & Li, C. (2019). Low-Power FPGA-based Deep Learning Accelerator for Real-Time Image Processing in UAV. *IEEE Access*, 7, 72054–72064.

20. Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612.
21. Czaja, W., & Klos, A. (2019). Power Line Inspection Using Unmanned Aerial Vehicles. In: *High-Voltage Test and Measurement*. IntechOpen.
22. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*.
23. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
24. Al-Shayea, Q. (2009). Artificial Neural Networks in Pattern Recognition. *International Journal of Advanced Science and Technology*, 8, 49-65.
25. Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504–507.
26. Tieleman, T., & Hinton, G. (2012). Lecture 6.5—R.M.S. Prop. COURSERA: Neural Networks for Machine Learning.
27. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15(1), 1929–1958.
28. Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1, 511–518.
29. P. F. (2016). TFlern: A Modular Deep Learning Library for TensorFlow. *Journal of Open Source Software*, 1(3), 44.
30. Al-Shaikh, A., Jobin, M., & Rahman, S. (2019). Machine learning based method for power line fault detection and classification. *IEEE Transactions on Smart Grid*, 10(4), 4381–4390.

31. Faisal, M. A., Mecheter, I., Qiblawey, Y., Hernández Fernández, J., Chowdhury, M. E. H., & Kiranyaz, S. Deep Learning in Automated Power Line Inspection: A Review. (2024)
32. Kiranyaz, S., Ince, T., & Gabbouj, M. 1D convolutional neural networks and applications: A survey. (2021)
33. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A. H., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Farhan, L., & Alam, M. Review of deep learning: concepts, CNN architectures, challenges, and future directions. (2021)
34. Ejaz, F., Hwang, L. K., Son, J., Kim, J.-S., Lee, D. S., et al. Convolutional neural networks for approximating electrical and thermal conductivities of Cu–CNT composites. *Scientific Reports*, 12, Article 13614 (2022)
35. DCPLD-Net: A diffusion coupled convolution neural network for real-time power transmission lines detection from UAV-borne LiDAR data.
36. UAV Inspections of Power Transmission Networks with AI Technology. *Energies*, 17(14) (2024)
37. UAV Visual and Thermographic Power Line Detection Using Deep Learning (YOLOv8). *Sensors*, 24(17) (2024)
38. Zhao, Xia; Wang, Limin; Zhang, Yufei; Han, Xuming; Deveci, Muhammet; Parmar, Milan. “A Review of Convolutional Neural Networks in Computer Vision.” *Artificial Intelligence Review*, 2024, vol. 57, article number 99.
39. “An Extensive Study of Convolutional Neural Networks: Applications in Computer Vision for Improved Robotics Perceptions.” *Sensors*, 2025, 25(4), 1033.
40. Alaca, Ozgur; Ekti, Ali Riza; Wilson, Aaron J.; Snyder, Isabelle B.; Stenvig, Nils M. “CNN-Based Phase Fault Classification in Real and Simulated Power Systems Data.” *Proceedings of the 2024 IEEE Power & Energy Society General Meeting (PESGM)*, 2024.
41. “Power System Waveform Classification Using Time-Frequency and CNN.” ORNL Technical Conference Paper.

42. "A Survey on Efficient Convolutional Neural Networks and Hardware Acceleration." *Electronics*, 2022, 11(6), 945.
43. "A Survey of Convolutional Neural Networks on Edge with Reconfigurable Computing." *Algorithms*, MDPI.
44. Yan, Jiamiao. "Application of CNN in Computer Vision." *Applied and Computational Engineering*, 2024, volume 30, issue 1, pages 104-110.

## **ДОДАТКИ**

## Додаток А

Лістинг А.1. Фрагмент коду навчання згорткової нейронної мережі (ЗНМ) для класифікації зображень ЛЕП

```
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D,
Flatten, Dense, Dropout
from tensorflow.keras.optimizers import Adam
import numpy as np
import os

# --- 1. ПАРАМЕТРИ МОДЕЛІ ---
# Розмір зображень, який був визначений як оптимальний
IMG_SIZE = (150, 150)
# Кількість каналів (3 для RGB,
# для більшої точності використовуємо 3, як типово для вхідних
зображень)
IMG_CHANNELS = 3
# Кількість класів: 2 (пошкоджена/непошкоджена ЛЕП)
NUM_CLASSES = 2
# Швидкість навчання,
LEARNING_RATE = 1e-3 # 1e-3
# Кількість епох, достатня для детекції стану
EPOCHS_COUNT = 5 # П'ять епох виявилось достатньо для детекції
стану
# Розмір пакета
BATCH_SIZE = 32

# --- 2. ІМІТАЦІЯ ЗАВАНТАЖЕННЯ ТА ПІДГОТОВКИ ДАНИХ ---
# В проекті використовується
tf.keras.preprocessing.image_dataset_from_directory
# або інший завантажувач для 4500 навчальних і 500 валідаційних
зразків.

def load_data(img_size, img_channels, num_samples):
    # Генерація даних для демонстрації
    print(f"Імітація завантаження {num_samples} зображень...")
    data = np.random.rand(num_samples, img_size[0], img_size[1],
img_channels).astype('float32')
```

```

    # Нормалізація вхідних даних (від -0.9 до +0.9)
    data = (data * 1.8) - 0.9
    labels = np.random.randint(0, NUM_CLASSES,
size=(num_samples, 1))
    return data, labels

# Кількість навчальних та валідаційних зразків
TRAIN_SAMPLES = 4500
VALIDATION_SAMPLES = 500
TEST_SAMPLES = 8000

# Завантаження даних
X_train, y_train = load_data(IMG_SIZE, IMG_CHANNELS,
TRAIN_SAMPLES)
X_val, y_val = load_data(IMG_SIZE, IMG_CHANNELS,
VALIDATION_SAMPLES)
# X_test, y_test = load_data(IMG_SIZE, IMG_CHANNELS,
TEST_SAMPLES) # Тестовий набір

# --- 3. АРХІТЕКТУРА ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ ---
# Використовується комбінація 2D згорткових та max_pool_2d
пулінгових шарів

model = Sequential([
    # Перший згортковий блок
    Conv2D(32, (3, 3), activation='relu',
input_shape=(IMG_SIZE[0], IMG_SIZE[1], IMG_CHANNELS)),
    # Використання ReLU, оскільки він 'не буде схильний до
проблем зникнення градієнта'
    MaxPooling2D((2, 2)),

    # Другий згортковий блок
    Conv2D(64, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),

    # Третій згортковий блок (додатковий шар для узагальнення
ознак)
    Conv2D(128, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),

    # Вирівнювання
    Flatten(),

```

```

    # Повністю зв'язаний шар
    Dense(512, activation='relu'),
    # Вихідний шар з функцією Softmax, як 'функція втрат' для
класифікації
    Dense(NUM_CLASSES, activation='softmax')
])

# --- 4. КОМПІЛЯЦІЯ МОДЕЛІ ---
# Використовуємо оптимізатор Adam та перехресну ентропію як
функцію втрат (для Softmax)
# 'Функція softmax. Ця функція є перехресною ентропією'
model.compile(optimizer=Adam(learning_rate=LEARNING_RATE),
              loss='sparse_categorical_crossentropy', #
Використання sparse_... для цілих міток класів
              metrics=['accuracy'])

# Ініціалізація ваг: 'зсуви ініціалізуються нулем, а ваги
ініціалізуються близько до нуля'
# У Keras це відбувається автоматично за замовчуванням для
більшості шарів.

print("\n--- СТРУКТУРА МОДЕЛІ ---")
model.summary()

# --- 5. НАВЧАННЯ МОДЕЛІ ---
print("\n--- ПОЧАТОК НАВЧАННЯ ---")
history = model.fit(
    X_train, y_train,
    epochs=EPOCHS_COUNT,
    batch_size=BATCH_SIZE,
    validation_data=(X_val, y_val),
    verbose=2 # Вивід однієї лінії на епоху
)

# --- 6. ОЦІНКА РЕЗУЛЬТАТІВ ---
print("\n--- ОЦІНКА ПІСЛЯ НАВЧАННЯ ---")
# 'Коли досягається оптимальна продуктивність або
спостерігається,
# що навчання досягло піку, навчання моделі завершується.'

# Точність валідації після останньої епохи
val_accuracy = history.history['val_accuracy'][-1] * 100
print(f"Фінальна точність валідації: {val_accuracy:.2f}%")

```

```
if val_accuracy >= 90:
    print("Цільову ефективність 90% або вище досягнуто.")
else:
    print("Необхідне додаткове навчання або коригування гіперпараметрів.")
```