

Міністерство освіти і науки України
Харківський національний університет імені В. Н. Каразіна
Навчально-науковий інститут «Українська інженерно-педагогічна академія»
Кафедра електротехніки та електроенергетики

КВАЛІФІКАЦІЙНА РОБОТА

магістра

на тему

ДОСЛІДЖЕННЯ ВПЛИВУ ЗАБРУДНЕННЯ НА ВТРАТИ ПОТУЖНОСТІ ФОТОЕЛЕКТРИЧНИХ ПАНЕЛЕЙ

(тема кваліфікаційної роботи)

Виконав: студент 2 маг. курсу, групи ЗЕБ-24мг
спеціальності: 141 Електроенергетика,
електротехніка та електромеханіка

_____ / Оксана КОСТІНА

(підпис) (ім'я та прізвище)

Керівник _____ / Павло ВАСЮЧЕНКО

(підпис) (ім'я та прізвище)

Рецензент _____ / Олег ПОДОЛЯК

(підпис) (ім'я та прізвище)

«До захисту допущено»

Завідувач кафедри _____ / Артем ЧЕРНЮК

(підпис) (ім'я та прізвище)

Секретар ЕК _____ / Ігор КИРИСОВ

(підпис) (ім'я та прізвище)

Харків – 2025 рік

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ХАРКІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ІМЕНІ В. Н. КАРАЗІНА

Навчально – науковий інститут Українська інженерно-педагогічна академія
Кафедра електротехніки та електроенергетики
Спеціальність 141 Електроенергетика, електротехніка та електромеханіка
Освітньо-професійна програма Енергетична безпека

ЗАТВЕРДЖУЮ
Завідувач кафедри

(підпис)

к.т.н., доцент Артем ЧЕРНЮК
(науковий ступінь, вчене звання, ім'я, прізвище)

«___» _____ 2025 р.

ЗАВДАННЯ

на кваліфікаційну роботу дипломну роботу
другого (магістерського) рівня вищої освіти

здобувачу вищої освіти Оксані КОСТІНОЙ

1. Тема «ДОСЛІДЖЕННЯ ВПЛИВУ ЗАБРУДНЕННЯ НА ВТРАТИ
ПОТУЖНОСТІ ФОТОЕЛЕКТРИЧНИХ ПАНЕЛЕЙ»

затверджена наказом по академії № 4801-5/3664 від «06» жовтня 2025 р.

2. Термін здачі закінченої роботи « 10 » _____ 12 _____ 2025 р.

3. Вихідні дані до роботи/проєкту: Рівень напруги, умови експлуатації,
характеристика струмоведучих частин, типи кабельних ліній, метод апарат
дослідження, завдання, параметри обладнання

4. Зміст роботи/проєкту (перелік питань, які належить розробити):

Вступ. Перелік умовних позначень. 1. ВИЯВЛЕННЯ ЗАБРУДНЕННЯ
ФОТОЕЛЕКТРИЧНИХ МОДУЛІВ ЗА ДОПОМОГОЮ ВІЗУАЛІЗАЦІЇ
ВИДИМОГО СПЕКТРУ ТА МАШИННОГО НАВЧАННЯ 2. ОЦІНКА ВТРАТ
ПОТУЖНОСТІ ЗАБРУДНЕНОЇ ФОТОЕЛЕКТРИЧНОЇ ПАНЕЛІ ЗА
ДОПОМОГОЮ МЕТОДІВ АНАЛІЗУ ЗОБРАЖЕНЬ 3. ЕМПІРИЧНА МОДЕЛЬ
4. АНАЛІЗ РЕЗУЛЬТАТІВ ДОСЛІДЖЕННЯ. Висновки. Список посилань

5. Перелік графічного матеріалу (презентаційний матеріал):

Слайди презентації

6. Консультант:

Розділ	Консультант	Підпис, дата		Оцінка (бали)
		Завдання видав	Завдання прийняв	

7. Дата видачі завдання «12» жовтня 2025 р.

Керівник

(підпис)

Павло ВАСЮЧЕНКО

(ім'я, прізвище)

Завдання прийняв до виконання

(підпис)

Оксана КОСТИНА

(ім'я, прізвище)

КАЛЕНДАРНИЙ ПЛАН-ГРАФІК виконання кваліфікаційної дипломної роботи

№ з/п	Назва етапів роботи та питань, які мають бути розроблені відповідно до завдання		Термін виконання	Позначки керівника про виконання завдань
1	Визначення актуальності теми дослідження		02.10.25 – 05.10.25	
2	Проведення аналізу наукової літератури		06.10.25 – 15.10.25	
3	Виконання першого розділу дипломної роботи		16.10.25 – 29.10.25	
4	Виконання другого та третього розділу дипломної роботи		30.10.25 – 26.11.25	
5	Оформлення пояснювальної записки		27.11.25 – 07.12.25	

Студент (ка)

(підпис)

Оксана КОСТИНА

(ім'я, прізвище)

РЕФЕРАТ

Магістерська робота виконана на 69 стр., містить 6 таблиці, 16 рисунків, що характеризують результати дослідження, використано 89 літературних посилань.

Об'єкт дослідження – фотоелектричні панелі.

Предм дослідження – втрати потужності фотоелектричних панелей.

Тема магістерської роботи – дослідження впливу забруднення на втрати потужності фотоелектричних панелей.

Однією з найважливіших умов ефективної роботи сонячних електростанцій з великою встановленою потужністю є забезпечення систематичного моніторингу стану поверхні фотоелектричних модулів. Ця процедура спрямована на своєчасне виявлення зовнішніх пошкоджень модулів, а також їх часткового затінення. Здійснення цих заходів виключно шляхом візуального огляду обслуговуючим персоналом електростанції вимагає значної трудомісткості через великі площі генеруючих полів та умови експлуатації.

Існують підходи, спрямовані на підвищення енергоефективності потужних сонячних електростанцій шляхом автоматизації процедур огляду поверхонь фотоелектричних модулів. Рішення базується на використанні різних засобів з корисним навантаженням, здатного записувати відео та геопросторові дані. Для виконання процедур виявлення проблемних модулів пропонується використовувати технологію «виявлення об'єктів», яка використовує методи класифікації нейронних мереж, що характеризуються високою адаптивністю до різних параметрів зображення. Результати тестування технології показали, що використання нейронної мережі на основі архітектури R-CNN з алгоритмом навчання Inception v2 (COCO) дозволяє виявляти проблемні фотоелектричні модулі з точністю понад 95% у ясний день.

Ключові слова: МОНІТОРИНГ; ДІАГНОСТИКА; СОНЯЧНІ ЕЛЕКТРОСТАНЦІЇ; ФОТОЕЛЕКТРИЧНІ МОДУЛІ; НЕЙРОННІ МЕРЕЖІ; МАШИННИЙ ЗІР, ВТРАТИ ПОТУЖНОСТІ, ФОТОЕЛЕКТРИЧНІ ПАНЕЛІ, ЗАБРУДНЕННЯ ФОТОЕЛЕКТРИЧНИХ ПАНЕЛЕЙ, ВТРАТИ ПОТУЖНОСТІ ФОТОЕЛЕКТРИЧНИХ ПАНЕЛЕЙ.

ABSTRACT

The master's work is completed on 69 pages, contains 6 tables, 16 figures characterizing the results of the research, 89 literary references are used.

The object of the study is photovoltaic panels.

The subject of the study is power losses of photovoltaic panels.

The topic of the master's thesis is the study of the impact of pollution on the power losses of photovoltaic panels.

One of the most important conditions for the effective operation of solar power plants with a large installed capacity is to ensure systematic monitoring of the surface condition of photovoltaic modules. This procedure is aimed at timely detection of external damage to the modules, as well as their partial shading. The implementation of these measures solely by visual inspection by the power plant maintenance personnel requires significant labor intensity due to the large areas of generating fields and operating conditions.

There are approaches aimed at increasing the energy efficiency of powerful solar power plants by automating the procedures for inspecting the surfaces of photovoltaic modules. The solution is based on the use of various payloads capable of recording video and geospatial data. To perform the procedures for detecting problematic modules, it is proposed to use the "object detection" technology, which uses neural network classification methods characterized by high adaptability to various image parameters. The results of testing the technology showed that the use of a neural network based on the R-CNN architecture with the Inception v2 (COCO) learning algorithm allows detecting problematic photovoltaic modules with an accuracy of over 95% on a clear day.

Keywords: MONITORING; DIAGNOSTICS; SOLAR POWER PLANTS; PHOTOELECTRIC MODULES; NEURAL NETWORKS; MACHINE VISION, POWER LOSSES, PHOTOELECTRIC PANELS, PHOTOELECTRIC PANELS POLLUTION, PHOTOELECTRIC PANELS POWER LOSSES.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ	7
ВСТУП	9
РОЗДІЛ 1 ВИЯВЛЕННЯ ЗАБРУДНЕННЯ ФОТОЕЛЕКТРИЧНИХ МОДУЛІВ ЗА ДОПОМОГОЮ ВІЗУАЛІЗАЦІЇ ВИДИМОГО СПЕКТРУ ТА МАШИННОГО НАВЧАННЯ	10
1.1. Існуючі методи нейромережевого моніторингу та діагностики фотоелектричних модулів	11
1.2. Платформа для використання автоматизованого комплексу	13
1.3. Вибір архітектури нейронної мережі	16
1.4. Створення навчальної вибірки	16
1.5. Аналіз результатів дослідження	20
1.6. Результати досліджень	26
ВИСНОВКИ ДО РОЗДІЛУ 1	29
РОЗДІЛ 2. ОЦІНКА ВТРАТ ПОТУЖНОСТІ ЗАБРУДНЕНОЇ ФОТОЕЛЕКТРИЧНОЇ ПАНЕЛІ ЗА ДОПОМОГОЮ МЕТОДІВ АНАЛІЗУ ЗОБРАЖЕНЬ	30
2.1. Забруднення – як одна з основних проблем фотоелектричної енергетики	30
2.2. Матеріали та методи	32
2.2.1 Симулятор пилу	33
2.2.2. Прилади, що використовуються для збору даних	34
2.2.3. Налаштування обладнання в експериментальних випробуваннях	34
2.2.4. Методологія систематичного захоплення зображень	36
ВИСНОВКИ ДО РОЗДІЛУ 2	38
РОЗДІЛ 3 ЕМПІРИЧНА МОДЕЛЬ	39
3.1. Оцінка стану на основі аналізу зображень	39
3.2. Аналіз даних	43
ВИСНОВКИ ДО РОЗДІЛУ 3	49

РОЗДІЛ 4. АНАЛІЗ РЕЗУЛЬТАТІВ ДОСЛІДЖЕННЯ	50
4.1. Оцінка точності наборів даних – зображення одного й того ж набору даних	50
4.2. Тестування моделі	52
ВИСНОВКИ ДО РОЗДІЛУ 4	55
ВИСНОВКИ Й РЕКОМЕНДАЦІЇ	56
<u>Додаток А</u>	57
<u>Додаток Б</u>	58
СПИСОК ПОСИЛАНЬ	59

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

ВН – висока напруга

ЕММ – електромагнітний момент

ЕМП – електромагнітні поля

ЕМС – електромагнітні сили

КЛ – кабельні лінії

ЛЕП – лінії електропередач

ММ – математичні моделі

МГЕ – метод граничних елементів

МКЕ – метод кінцевих елементів

МКР – метод кінцевих різниць

ПЕР – паливно–енергетичні ресурси

СНАУ – система нелінійних алгебраїчних рівнянь

СЛАУ – система лінійних алгебраїчних рівнянь

FEMM – Finite Element Method Magnetics

ВЕУ – вітроелектростанція

ВТ – вітротурбіна

ДГ – дизель генератор

ПДЕ – поновлювальні джерела енергії

СЕП – система електропостачання

ФЕУ – фотовольтанична електрична станція

ШПТ – шина постійного струму

ВСТУП

Забруднення є однією з основних проблем фотоелектричної енергетики. За оцінками, в деяких зонах може накопичуватися до 0,6 % ґрунту на день. Це, разом із відсутністю опадів у посушливих зонах, призводить до значних втрат енергії. Виявлення ґрунту раніше досліджувалося в літературі з використанням методів штучного інтелекту, які вимагають великої кількості зображень для навчання. Пропонується алгоритмічний підхід, який зосереджується на характеристиках зображень для розрізнення різних рівнів забруднення. Запропонований метод вимагає створення симулятора забруднення для нанесення шарів ґрунту на модуль під час вимірювання електричних змінних. З отриманих наборів даних встановлюється калібрувальний вектор, який дозволяє оцінити потужність, що виробляється забрудненою панеллю, на основі її захопленого зображення. Максимальна похибка становить приблизно 3 % при застосуванні моделі до зображень власного набору даних. Похибка тоді змінюється від 3 % до 10 % при визначенні потужності з іншого набору даних і до 10 % при застосуванні моделі до зовнішнього набору даних. Ми вважаємо, що ця робота є новаторською в оцінці потужності, що виробляється забрудненою панеллю, шляхом вивчення лише зображення.

Метою даного дослідження є дослідження впливу забруднення на втрати потужності фотоелектричних панелей.

У зв'язку з цим **темою** цієї магістерської роботи є Дослідження впливу забруднення на втрати потужності фотоелектричних панелей.

Об'єктом дослідження – фотоелектричні панелі.

Предмет дослідження – втрати потужності фотоелектричних панелей.

РОЗДІЛ 1 ВИЯВЛЕННЯ ЗАБРУДНЕННЯ ФОТОЕЛЕКТРИЧНИХ МОДУЛІВ ЗА ДОПОМОГОЮ ВІЗУАЛІЗАЦІЇ ВИДИМОГО СПЕКТРУ ТА МАШИННОГО НАВЧАННЯ

Під час експлуатації промислових сонячних електростанцій (СЕС) систематично виникають проблеми, пов'язані із забрудненням та пошкодженням фотоелектричних модулів, що значно знижує їх енергоефективність та тягне за собою фінансові втрати для компаній, що обслуговують станції [1, 2, 3, 4]. У зв'язку з цим перед керівництвом компаній стоїть завдання систематичного моніторингу та діагностики стану поверхні фотоелектричних модулів. Впровадження цих процедур дозволить швидко реагувати та усувати виникаючі проблеми, що призведе до підвищення енергоефективності установки [5, 6].

Моніторинг та діагностика стану поверхні фотоелектричних модулів є актуальними завданнями для всіх промислових сонячних електростанцій у світі та вже мають низку основних традиційних рішень, наприклад: візуальний огляд поверхні фотоелектричних модулів персоналом сонячної електростанції, вимірювання та контроль електричних параметрів шляхом встановлення спеціалізованих датчиків, а також фотофіксація поверхні модулів за допомогою безпілотних літальних апаратів (БПЛА) з подальшою ручною обробкою фото- та відеоматеріалів [7, 8, 9, 10, 11, 12]. Ці рішення недостатньо ефективні, а їх використання пов'язане з великими часовими та фінансовими витратами, через необхідність встановлення спеціалізованих датчиків у кожній з гірлянд модулів та або переналаштування схеми станції, або «ручного» огляду всіх модулів, встановлених на території СЕС.

Таким чином, існує потреба в розробці нових методів і підходів до діагностики та моніторингу поверхні фотоелектричних модулів, основою яких мають бути нові технології, повністю або частково позбавлені вищезазначених недоліків. Тому було вирішено розглянути можливість автоматизації технології моніторингу шляхом комбінованого використання передових технологій машинного зору на основі використання нейронних мереж (НМ) та БПЛА.

1.1. Існуючі методи нейромережевого моніторингу та діагностики фотоелектричних модулів

Нейронні мережі є ефективним інструментом для паралельної обробки інформації та створення узагальнень, достатньо достовірних результатів на основі даних, які не використовувалися в процесі навчання [13, 14, 15]. Саме завдяки цій особливості нейронні мережі вже зарекомендували себе в різних галузях промисловості та енергетичної галузі (атомна енергетика, вітроенергетика) [16, 17, 18, 19, 20], є одним з інструментів для моніторингу та діагностики різних енергетичних об'єктів (трубопроводів, вітрових турбін, ліній електропередач) [21, 22, 23, 24], а також широко використовуються для виявлення та моніторингу стихійних лих [25, 26]. Використання нейромережевих технологій для вирішення задач моніторингу об'єктів критичної інфраструктури свідчить про надійність їх роботи та мінімальні похибки в результатах. Таким чином, використання нейромережевих технологій видається ефективним рішенням для автоматизації процедур моніторингу та діагностики фотоелектричних модулів.

Існує кілька основних способів використання нейронної мережі в SPP:

(1). Термографічний метод. Метод базується на нейромережевому аналізі даних, отриманих під час зйомки модулів за допомогою інфрачервоної камери, прикріпленої до БПЛА [27, 28, 29]. Метод, призначений для пошуку суттєво перегрітих ділянок (гарячих точок) фотоелектричних модулів, що виникають внаслідок збільшення опору модулів через їх тривале затінення. До переваг цього методу належить можливість його використання на будь-якій сонячній електростанції, без виконання підготовчих робіт, пов'язаних зі зміною конструктивних рішень станції та встановленням додаткових датчиків. Однак використання цього рішення ускладнюється повільним процесом захоплення об'єктів, що цікавлять, інфрачервоною камерою. З огляду на це, для отримання коректних даних потрібно суттєво обмежити швидкість польоту БПЛА. Крім того, це рішення є неефективним для оперативного реагування на виниклі

проблеми, через необхідність «вручну» визначати місцезнаходження проблемного об'єкта, а також неможливість точно визначити причину виникнення гарячої точки.

Аналіз електричних даних. Метод, заснований на нейромережевому аналізі даних, отриманих від датчиків електричних параметрів, встановлених у фотоелектричних модулях [30, 31, 32]. Підхід дозволяє виявити різні типи пошкоджень модулів, на яких навчалася використана нейронна мережа. Цей метод є дорогим, через необхідність встановлення великої кількості додаткових датчиків, а також змін у схемних та конструктивних рішеннях сонячної електростанції. Метод може бути ефективно використаний лише на станціях з встановленим комплектом необхідного обладнання.

Симуляційне моделювання. Метод, що базується на нейромережевій імітації процесів, що відбуваються у фотоелектричних модулях (за відомих значень сонячної радіації, температури тощо), та порівнянні їх з отриманими реальними даними [33, 34]. Використання цього рішення ускладнюється різноманітністю та мінливістю факторів, що впливають на роботу фотоелектричних модулів.

У таблиці 1.1 представлено зведений результат якісної оцінки методів моніторингу та діагностики поверхні розглянутих фотоелектричних модулів.

Таблиця 1.1 – Якісна оцінка методів

Метод	Швидкість роботи	Точність виявлення	Інформація про проблему	Вартість	Складність впровадження
Термографічний метод	Повільно	Середній	Низький	Високий	Легко
Аналіз електричних даних	Швидкий	Високий	Низький	Високий	Важко
Моделювання симуляції	Швидкий	Низький	Низький	Середній	Середній
Запропонований метод	Звичайний	Середній	Високий	Низький	Легко

Оскільки описані методи мають низку недоліків, для вирішення проблеми моніторингу та діагностики СПП пропонується використовувати інший підхід, який поєднує окремі переваги представлених вище методів (традиційного та нейромережевого), дозволяючи їм компенсувати їхні слабкі сторони. Такий підхід забезпечить автоматичне визначення координат проблемних модулів з їх

візуалізацією на інтерактивній карті, завдяки комплексному використанню технологій, заснованих на використанні БПЛА та методів машинного зору, що реалізують нейромережеву класифікацію. Використання таких систем є наступним логічним кроком у розробці автоматизованих комплексів для моніторингу об'єктів, розташованих на великих територіях.

1.2. Платформа для використання автоматизованого комплексу

Наразі вже існує низка прикладів успішного використання БПЛА зі встановленим спеціалізованим обладнанням для моніторингу, яке дозволяє вирішувати задачі розпізнавання та класифікації різних об'єктів (людей, автомобілів, будівель тощо) [35, 36, 37, 38, 39]. Вирішення вищезазначених завдань пов'язане з реалізацією складних, багаторівневих процесів, таких як обробка та фільтрація даних, інтелектуальний аналіз зображень, а також розпізнавання та класифікація різних об'єктів. Реалізація вищезазначених процесів пов'язана з використанням високої обчислювальної потужності для швидкої та коректної обробки отриманих даних, що накладає певні обмеження на режими роботи та використовуване обладнання. З огляду на це, вибір платформи для автоматизованого комплексу є важливим завданням.

Під час розробки комплексу розглядалися три основні варіанти реалізації нейромережевого аналізу фото- та відеоданих, отриманих за допомогою камери БПЛА:

Аналіз даних нейронної мережі виконується на БПЛА за допомогою бортового програмно-апаратного комплексу [40, 41, 42]. Суть цього варіанту полягає в обробці відеопотоку камери БПЛА безпосередньо на борту пристрою з подальшим відправленням результатів аналізу на персональний комп'ютер СПП, де дані будуть інтерпретовані та відображені на інтерактивній карті станції. Такий метод дозволить будувати карту проблемних фотоелектричних модулів у режимі реального часу, а також дистанційно направляти БПЛА в зони

інтересу станції. Однак вирішення цих проблем вимагає високої обчислювальної потужності, що накладає певні обмеження на режим роботи БПЛА та негативно впливає на його можливості. Це пов'язано з тим, що для отримання задовільних результатів розпізнавання та класифікації об'єктів інтересу потрібно отримувати зображення або відеозображення з досить високою роздільною здатністю, що призводить до значного зниження швидкості їх аналізу. Досвід використання таких систем показує, що обробка одного зображення з роздільною здатністю 1920×1080 пікселів, за допомогою бортових обчислювальних пристроїв, може бути виконана протягом кількох секунд. В результаті цього необхідно обмежувати швидкість руху БПЛА, що негативно впливає на час його польоту. Крім того, при реалізації цього варіанту важливо враховувати, що дистанційна передача відеоданих пов'язана з виникненням перешкод та спотворень у сигналі, що призводить до необхідності розробки методу завадостійкого кодування даних з подальшою процедурою декодування. Водночас слід також зазначити, що наявність високопродуктивного обчислювального пристрою на борту є додатковим електричним та ваговим навантаженням для БПЛА.

Нейромережевий аналіз виконується на БПЛА за допомогою програмованого логічного пристрою (ПЛП) [43]. Суть цього варіанту аналогічна вищезазначеному, але відмінності полягають в інструменті для виконання нейромережевого аналізу. ПЛП базуються на використанні великої кількості логічних елементів, які об'єднані в єдину систему. Цей метод передбачає збільшення швидкості аналізу даних, завдяки можливості паралельної обробки, що значно збільшить швидкість БПЛА порівняно з першим варіантом. Використання ПЛП пов'язане зі збільшенням енергоспоживання та зростанням вартості комплексу через більшу кількість елементів, що використовуються для вирішення задач, та складність зв'язку між ними. Крім того, залишається проблема дистанційної передачі відеоданих, що вимагатиме розробки методу кодування та декодування. Крім того, при використанні ПЛП ускладнюється налагодження та вдосконалення розроблюваного автоматизованого комплексу, через необхідність значних програмних та фізичних змін у використовуваних

схемі при внесенні будь-яких коригувань до проектованої системи. Використання ПЛІ може бути ефективним лише після остаточної розробки, тестування, налагодження та польових випробувань розробленого комплексу.

Нейромережевий аналіз виконується на віддаленому сервері, а БПЛА використовується виключно для отримання відеоданих [44, 45]. Оскільки вирішення задачі моніторингу сонячної електростанції не вимагає виявлення та класифікації проблемних зон у режимі реального часу, що ще більше ускладнюється вищезазначеними факторами, з'являється можливість перенести всі розрахунки на віддалений сервер. Як сервер може бути використаний персональний комп'ютер СЕС або спеціально придбане обладнання, вартість та конфігурація якого залежатимуть від поточних та майбутніх потреб станції, а також його можна буде вдосконалювати з часом. Таким чином, керівництво станції зможе частково визначати обсяг фінансових витрат, які будуть необхідні для розгортання комплексу. Перенесення складних нейромережевих розрахунків на віддалений сервер також допоможе зменшити навантаження на БПЛА, що дозволить йому виконувати спочатку закладені в нього функції, тобто політ над територією сонячної електростанції та його відеозапис за заздалегідь складеним маршрутом польоту.

Таким чином, після аналізу можливих варіантів реалізації нейромережевого аналізу фото- та відеоданих, отриманих з камери БПЛА, було обрано варіант, під час якого аналіз даних виконується на віддаленому сервері. Використання сервера, яким може бути комп'ютер СПП, дозволить зменшити фінансові витрати на придбання та налагодження нового обладнання, виконувати аналіз відеоданих, працювати з інтерактивною картою та налаштовувати маршрут польоту БПЛА на одному комп'ютері. Фактично, буде створено місце для диспетчера, відповідального за діагностику та моніторинг фотоелектричних модулів. Диспетчер матиме доступ до всіх доступних даних: відео, фотографій, виявлених пошкоджень сонячних електростанцій тощо, протягом усього періоду експлуатації комплексу.

1.3. Вибір архітектури нейронної мережі

Розробка автоматизованого комплексу пов'язана зі створенням нейронної мережі, основним завданням якої є виявлення проблемних зон СПП за допомогою використання технологій машинного зору та нейромережевої класифікації. Найвищу точність розпізнавання об'єктів на зображеннях, порівняно з нейронними мережами інших типів, демонструють згорткові нейронні мережі глибокого навчання [46, 47, 48]. Наразі розроблено досить велику кількість надточних алгоритмів нейронних мереж, серед яких найперспективнішими є: SqueezeNet, ResNet, MobileNet, Inception, DenseNet, AlexNet та YOLO [49, 50]. Під час дослідження ці алгоритми були проаналізовані з точки зору швидкості та точності роботи, а також необхідних апаратних потужностей для виявлення забруднення, затінення та пошкодження поверхні фотоелектричних модулів.

Результати аналізу наведено в таблиці 1.2. З них випливає, що для вирішення задачі моніторингу сонячної електростанції алгоритм InceptionV2 є найоптимальнішим, оскільки є найточнішим та не ресурсоємним порівняно з іншими.

1.4. Створення навчальної вибірки

Для коректного навчання нейронної мережі та її подальшого використання потрібно створити розширену навчальну вибірку, що складається з великого набору даних, подібного до того, що буде використано в роботі [52, 53]. Для діагностики та моніторингу поверхні фотоелектричних модулів, як набір даних, доцільно використовувати розкадровані відеофайли, що містять дані про об'єкти території промислових сонячних електростанцій.

Таблиця 1.2. – Швидкість аналізу даних нейронними мережами різних архітектур [51].

Архітектура	Час, мс	Точність, %	Рахунок
SSDLite MobileNet v2 COCO	27	53	5/90
SSD-накопичувач Inception v2 COCO	42	65	6/88.8
Швидший R-CNN Inception v2 COCO	58	94	1/111.2
Швидший R-CNN ResNet101 COCO	106	86	4/95.4
Швидше R-CNN Resnet101 низькі пропозиції COCO	82	75	7/87.2
Швидший R-CNN Inception ResNet v2 atrous COCO	620	60	11/61.6
Швидший R-CNN Inception ResNet v2 atrous	241	71	10/75.1
низькі пропозиції COCO	1833 рік	86	8/86,5
Швидший R-CNN NAS	540	82	9/83.9
Швидший R-CNN з низькими пропозиціями COCO	84	99	2/110.9
YOLOv3	110	100	3/109.1
Початок, версія 3	27	53	5/90

У процесі створення навчальної вибірки для нейронної мережі були встановлені такі критерії умов відеозапису фотоелектричних модулів за допомогою БПЛА:

а. Відеозапис фотоелектричних модулів слід здійснювати камерою БПЛА на висоті до п'яти метрів під кутом від 90° до 135° до поверхні модулів, під час польоту безпосередньо над гірляндою (рисунок 1.1).

б. Під час відеозйомки поверхні фотоелектричних модулів у налаштуваннях камери БПЛА необхідно вимкнути функцію автоматичної експозиції. Це необхідно для збереження деталей у світлих та темних ділянках (у разі недоекспонованого та переоекспонованого зображення за різних параметрів освітлення).

с. Відеозапис фотоелектричних модулів слід проводити в ясний день за швидкості вітру не більше 4 м/с. Це необхідно для забезпечення нормальних умов для маршруту польоту БПЛА.




Рисунок 1.1 – Приклад схеми відеозапису для фотоелектричних модулів БПЛА

Аналіз ефективності виконання процедур детектування нейронної мережі залежно від режимів відеозапису показав, що оптимальними параметрами відеозапису є роздільна здатність 1080p з частотою кадрів 30 FPS. Такий режим відеозапису дозволяє значно пришвидшити обробку даних нейронною мережею без зниження якості детектування та збільшення енергоспоживання відеокамери БПЛА. В результаті тестових польотів та відеозапису модулів вдалося створити навчальний набір з понад 500 зображень (рис. 1.2). Навчальна вибірка містить

зображення нормальних, затінених та пошкоджених модулів, що необхідно для підвищення якості детектування та мінімізації кількості хибнопозитивних результатів.




Рисунок 1.2. – Приклади зображень проблемних модулів з навчальної вибірки

Наступним кроком після створення навчальної вибірки є її розмітка. Процедура маркування зображень необхідна для перетворення даних вибірки (зображень) у змінні, «зрозумілі» для нейронної мережі, які вона може обробляти та узагальнювати [54]. Для розмітки (анотації) використовувався інструмент LabelImg (<https://github.com/heartexlabs/labelImg>, дата звернення: 28 серпня 2022 р.). Зображення навчальної вибірки були вручну позначені на два класи: «Normal_panel» та «Shaded_panel». Перший клас включає зображення фотоелектричних модулів з нормальною (незатіненою, чистою,

непошкодженою) поверхнею. Другий клас включає зображення з проблемними (затіненими, брудними, пошкодженими) фотоелектричними модулями.

1.5. Аналіз результатів дослідження

Таким чином, створення автоматизованого комплексу – це багатоетапний процес, загальну структуру якого можна представити у вигляді блок-схеми (рис. 1.3). Принцип його роботи полягає в нейромережевому аналізі відеофайлів, знятих БПЛА, що рухається вздовж маршруту польоту над фотоелектричними модулями. Всі зняті дані аналізуються для виявлення затінення та пошкоджень фотоелектричних модулів, які потім відображаються на інтерактивній карті СЕС.




Рисунок 1.3. – Алгоритм реалізації автоматизованого комплексу: (Червоний – створення нейронної мережі; Зелений – попередня підготовка до роботи комплексу; Синій – аналіз нейронної мережі)

Інтерактивна карта СЕС генерується на основі геотегів, знятих БПЛА під час обльоту території станції, а час виявлення проблемних ділянок визначається

нейронною мережею. Для побудови карти кадр виявлення синхронізується з часом геотегу, що дозволяє визначити проблемний фотоелектричний модуль з точністю до кількох метрів. Всі виявлені пошкодження позначаються на карті у вигляді геотегів з фотографією виявлених пошкоджень. Виведення геотегів з результатами аналізу нейронної мережі (фото модуля) дозволяє диспетчеру СЕС, перебуваючи на своєму робочому місці, визначити правильність виявлення, а також вибрати спосіб усунення проблеми.

Процес відображення виявлених проблемних зон промислової сонячної електростанції на інтерактивній карті пов'язаний з фіксацією маршруту польоту БПЛА, а також виведенням цих даних для подальшої обробки. БПЛА має GPS-маяк, який дозволяє відстежувати їхнє положення на карті, а також виконувати пошук у разі аварійної посадки, але доступ до цих даних обмежений ліцензованим програмним забезпеченням БПЛА. Геотаги та розшифровка даних чорної скриньки можуть бути надані виробником після запиту, надісланого з особистого кабінету користувача; однак, під час польових випробувань та тривалого процесу налагодження часті запити недоцільні. З огляду на це, було прийнято рішення самостійно виготовити GPS-трекер та встановити його на БПЛА як корисне навантаження. Структурна схема GPS-трекера показана на рисунку 1.4.




Рисунок 1.4. – Структурна схема GPS-трекера

Як основний мікроконтролер використовується ESP8266. Для отримання геопросторової інформації вимірювальний модуль має GPS-приймач на базі мікросхеми NEO-6M-0-001, що базується на мікросхемі Ublox NEO-6M STM. Цей модуль є автономним GPS-пристроєм з високопродуктивним процесором позиціонування u-blox 6. Для зв'язку з мікроконтролером використовується інтерфейс UART (TTL) з підтримуваною швидкістю передачі даних від 4800 до 230 400 бод, за замовчуванням 9600 бод. Журнал геотегів записується на карту пам'яті micro-SD. Для цього використовується спеціалізований модуль карти micro SD, який підключається до мікроконтролера через інтерфейс SPI.

Для визначення розрахункової ефективної продуктивності комплексу (контрольованої встановленою потужністю СЕС (Пн.) одним комплексом), розроблено математичну модель, яка дозволяє оцінити можливості запропонованого комплексу залежно від типу станції та БПЛА, метеорологічних параметрів та продуктивності обчислювального обладнання. Крім того, модель дозволяє розрахувати мінімальну кількість комплексів, необхідну для

забезпечення моніторингу та діагностики всієї СЕС, що є важливим аспектом оцінки економічної ефективності запропонованого рішення. Значення контрольованої потужності можна розрахувати за виразом (1.1).

$$N = GP_{ek_n} \int_0^D W dt - 2lGn, \quad (1.1)$$

де G – коефіцієнт, що враховує конструктивні особливості несучих конструкцій та основні характеристики модулів, (Вт/м); P_e – продуктивність обчислювального обладнання; k_n – коефіцієнт, що враховує частоту вильотів БПЛА; D – період світлового дня, (с); W – значення швидкості польоту БПЛА з урахуванням впливу вітру, (м/с); l – відстань між посадковою платформою та контрольованим рядом станції, (м); n – частота вильотів БПЛА.

Коефіцієнт структурних особливостей сонячної електростанції та основні характеристики фотоелектричних модулів (G), що визначає потужність секції сонячної електростанції, над якою БПЛА пролітає за одну секунду, розраховується з виразу (1.2).

$$G = \frac{PY}{h}, \quad (1.2)$$

де P – номінальна потужність фотоелектричного модуля, (Вт); Y – тип несучої конструкції модулів; h – загальний розмір модуля у напрямку руху БПЛА (м).

Параметр (P_e), що визначає обчислювальну потужність обладнання, розраховується згідно з виразом (1.3). Він описує швидкість обробки отриманих даних нейронною мережею та враховує час, необхідний для передачі даних з пам'яті БПЛА до обчислювального пристрою.

$$P_e = 0.8 \left(\frac{P^N}{P_{ref}^N} \right)^{0.91}, \quad (1.3)$$

де P^N – продуктивність обчислювального обладнання; P_{ref}^N – це еталонне значення продуктивності.

Частота вильотів БПЛА (N) показує кількість бойових вильотів, необхідних для обльоту території СПП за світловий день (D), а також частоту заміни акумуляторних батарей, значення якої має враховувати кліматичні умови, в яких експлуатується комплекс. Розраховується за формулою (1.4).

$$n = \frac{D}{d_{stc} k_n} (1 - P_e), \quad (1.4)$$

де d_{stc} – стандартний час розряду акумулятора БПЛА, (с); k_n – коефіцієнт частоти вильотів БПЛА з урахуванням кліматичних умов.

Коефіцієнт частоти відправлень визначається виразом (1.5).

$$k_n = 1 - \left((1.06 \times 10^{-2}) T - 3.329 \right)^2, \quad (1.5)$$

де T – температура навколишнього середовища (К).

Швидкість БПЛА під впливом вітру (V) розраховується з виразу (1.6) [55].

$$W = 0.5k \left(\sqrt{V + \frac{C_p \rho S_{uav} \cos(\varepsilon) U^3}{m}} + \sqrt{V - \frac{C_p \rho S_{uav} \cos(\varepsilon) U^3}{m}} \right), \quad (1.6)$$

де k – коефіцієнт, що враховує аеродинамічні особливості БПЛА; W – швидкість польоту БПЛА, (м/с); C_p – коефіцієнт опору БПЛА; ρ – густина повітря, (кг/м³); S_{uav} – площа БПЛА, що піддається впливу вітру, (м²); ε –

напрямок вітру відносно вектора руху БПЛА, (градуси); V – швидкість вітру, (м/с); m – маса БПЛА, (кг).

Швидкість польоту БПЛА встановлюється для забезпечення оптимальної якості виявлення з урахуванням типу несучої конструкції модулів та розраховується за виразом (1.7).

$$V = 16.2 \exp(-2.5QY^{0.03}), \quad (1.7)$$

де Q – встановлена якість виявлення (0...1).

Для попередньої оцінки техніко-економічної ефективності запропонованого рішення було проведено розрахунки втрат енергії фотоелектричної установки, що працює в умовах часткового затінення. Базова математична модель була складена на основі стандартних рівнянь, що характеризують режим роботи рівномірно освітленої фотоелектричної установки з послідовним перемиканням фотоелектричних перетворювачів [56, 57, 58]. На основі цієї моделі було отримано систему рівнянь, яка дозволяє розрахувати загальні втрати потужності фотоелектричної установки з нерівномірним затіненням (8).

$$\left\{ \begin{array}{l} P_{loss} = U_{1max} n_p I_{1max} - U_{1max} (n_p^l I'_1 + n_p^s I'_2), \\ I_{1max} = I_{ph} - I_0 \left[\exp \left(\frac{q(U_{1max} + I_{1max} R_s)}{n_s^l (AkT)} \right) - 1 \right], \\ \frac{q(U_{1max} + I_{1max} R_s)}{n_s^l (AkT)} - \ln \frac{I_0 + I_{ph}}{I_0 \left(1 + \frac{q(U_{1max} + I_{1max} R_s)}{n_s^l (AkT)} \right)} = 0, \\ I'_1 = I_{ph} - I_0 \exp \left(\frac{q(U_{2max} + I'_1 R_s)}{n_s^l (AkT)} \right), \\ I'_2 = n_s^s \left(I_{ph} - I_0 \exp \left(\frac{q(U_{2max} + I'_2 R_s + U_d)}{n_s^s (AkT)} \right) \right), \text{ at } U'_2 < U_{2max}, \\ I'_2 = n_s^s \left(I'_{ph} - I'_0 \exp \left(\frac{q(U_{2max} + I'_2 R_s + U_d)}{n_s^l (AkT)} \right) \right), \text{ at } U'_2 \geq U_{2max}, \end{array} \right. \quad (1.8)$$

де P_{loss} – втрати потужності від часткового затінення, (Вт); n_p – кількість струн, з'єднаних паралельно; U_{1max} і U_{2max} – значення напруги в точках максимальної потужності (МРР) паралельно з'єднаних ланцюгів, що працюють без затінення та з затіненням, (В); I_{1max} – значення струму в ланцюжках МРР без

затінення, (А); n_p^s – кількість затінених рядків; n_p^l – кількість незаштрихованих рядків; I_{ph} – фотострум затіненої струни (А); I'_{ph} – фотострум освітленої струни, (А); I_0 – зворотний струм насичення, (А); q — заряд електрона (Кл); R_s – послідовний опір модуля, (Ом); n_s^l – кількість нешунтованих сонячних елементів у ланцюжку без затінення; n_s^s – кількість нешунтованих діодних сонячних елементів у ланцюжку із затіненням; A – коефіцієнт ідеальності фотоелементів у модулі; k – в стала Больцмана, (Дж/К); T – температура фотоелементів модуля, (К); I'_1 – значення струму незатіненої струни при напрузі U_{2max} , (А); I'_2 – значення струму заштрихованої струни при напрузі U_{2max} , (А); $U_{день}$ – падіння напруги на шунтуючому діоді (В); U'_2 – напруга ланцюжка з шунтованими групами модулів (В).

Результати моделювання показали, що при частковому затіненні двох модулів з вісімнадцяти втрата потужності струни становить близько 50%; при затіненні одного модуля – близько 20%; при затіненні більше двох модулів генерація потужності струною практично не здійснюється (значення струму струни обмежене струмом затінених фотоелементів). Аналіз статистики, що відображає значення ймовірності виникнення часткового затінення на СЕС, у поєднанні з розрахунковими даними, отриманими в результаті математичного моделювання, та річним виробництвом енергії СЕС, показав, що своєчасне виявлення та усунення причин, що призводять до затінення, збільшить річне виробництво енергії СЕС, яке становить близько 2%, з чого випливає, що запропоноване авторами рішення досягне стадії окупності протягом півтора року.

1.6. Результати досліджень

Результати обробки нейронною мережею відеоматеріалів, отриманих за допомогою камери БПЛА, показано на рисунку 1.5. Проблемні ділянки, виявлені

нейронною мережею на поверхні фотоелектричних модулів, візуалізуються на інтерактивній карті СЕС (рисунок 1.6).




Рисунок 1.5. – Кадр з результатом класифікації стану поверхні фотоелектричних модулів за допомогою нейронної мережі.



Рисунок 1.6. – Приклад виводу інтерактивної карти.

Візуальний огляд записаних відеоматеріалів на тестованій ділянці станції площею 50 000 м² ^{показав}, що точність виявлення проблемних ділянок нейронною мережею становила 95%. З 20 виявлених під час візуального огляду затінь та пошкоджень поверхонь модулів помилка була допущена лише в одному випадку.

Запропонована авторами математична модель дозволяє розрахувати встановлену потужність сонячної електростанції, що контролюється комплексом, залежно від різних факторів. Цей параметр визначає мінімальну кількість автоматизованих систем, необхідних для моніторингу всієї станції. Оцінку ефективності запропонованого рішення було проведено на прикладі його використання для моніторингу чотирирядної сонячної фотоелектричної станції «Миколаївка» встановленою потужністю 69,9 МВт. Результати оцінки показали, що використання комплексу з БПЛА FIMI X8SE та обчислювальним пристроєм на базі графічного процесора RTX2080 дозволить здійснювати моніторинг встановленої потужності до 6,4 МВт. Таким чином, для забезпечення моніторингу цієї станції знадобиться близько 11 комплексів.

Для визначення техніко-економічної ефективності використання комплексу на потужних сонячних електростанціях було проведено розрахунки втрат енергії фотоелектричних модулів внаслідок їх часткового затінення. Результати розрахунків показали, що при частковому затіненні двох модулів з вісімнадцяти втрати потужності струни становлять близько 50%; при затіненні одного модуля – близько 20%, а при затіненні трьох і більше модулів струна практично не генерує енергію (значення струму струни обмежене струмом затінених фотоелементів). Таке зниження енергоефективності пов'язане з тим, що значення напруги в точках максимальної потужності струни з частковим затіненням та без нього неоднакові.

Аналіз статистики виникнення часткового затінення на СЕС, у поєднанні з розрахунковими даними, отриманими в результаті математичного моделювання річної виробки електроенергії сонячної електростанції, та реальними даними генерації станції, показав, що своєчасне виявлення та усунення причин, що призводять до затінення, збільшить річну виробку електроенергії сонячної електростанції на величину близько 2%, з чого випливає, що запропоноване авторами рішення досягне стадії окупності протягом півтора року.

ВИСНОВКИ ДО РОЗДІЛУ 1

Розроблений автоматизований комплекс для моніторингу та діагностики фотоелектричних модулів дозволяє вирішити задачу моніторингу стану сонячної електростанції в режимі реального часу. Відмінною особливістю його використання є висока швидкість та якість виявлення проблемних модулів. Попередні випробування показали, що точність класифікації становить не менше 95%. Крім того, до переваг комплексу можна віднести простоту впровадження в існуючі промислові сонячні електростанції. Це пов'язано з тим, що його функціонування не вимагає додаткових структурних змін в існуючій конструкції станції. Техніко-економічні обґрунтування впровадження цього рішення показують, що використання запропонованого комплексу підвищить енергоефективність електростанції на 2% завдяки своєчасній діагностиці та оперативному наданню інформації обслуговуючому персоналу.

Запропонована математична модель дозволяє розрахувати встановлену потужність сонячної електростанції, що контролюється комплексом, залежно від різних факторів. Цей параметр визначає мінімальну кількість автоматизованих систем, необхідних для моніторингу всієї станції. Оцінку ефективності запропонованого рішення було проведено на прикладі його використання для моніторингу чотирирядної сонячної фотоелектричної станції встановленою потужністю 69,9 МВт. Результати оцінки показали, що використання комплексу з БПЛА FIMI X8SE та обчислювальним пристроєм на базі графічного процесора RTX2080 дозволить здійснювати моніторинг встановленої потужності до 6,4 МВт. Таким чином, для забезпечення моніторингу цієї станції знадобиться близько 11 комплексів.

РОЗДІЛ 2. ОЦІНКА ВТРАТ ПОТУЖНОСТІ ЗАБРУДНЕНОЇ ФОТОЕЛЕКТРИЧНОЇ ПАНЕЛІ ЗА ДОПОМОГОЮ МЕТОДІВ АНАЛІЗУ ЗОБРАЖЕНЬ

2.1. Забруднення – як одна з основних проблем фотоелектричної енергетики

Сонячні панелі, незалежно від того, чи є вони фотоелектричними, концентрованими чи тепловими, зазвичай встановлюються в посушливих регіонах з високим рівнем інсоляції та низькою річною кількістю опадів. Ці місця пропонують оптимальні умови для виробництва сонячної енергії завдяки великій кількості сонячного світла. Однак ці зони схильні до значного накопичення пилу [1, 2, 3, 4]. Наявність пилу на панелях може призвести до зниження продуктивності [5, 6] та, що більш критично, до скорочення терміну їхньої служби [7]. Ступінь цих наслідків залежить від конкретної місцевості (чи є вона посушливою чи ні) та погодних умов, таких як вітер або дощ [8].

На продуктивність фотоелектричних установок суттєво впливає накопичення пилу, що призводить до зниження прибутковості, як повідомляє Програма фотоелектричних енергетичних систем Міжнародного енергетичного агентства [9]. Важливо зазначити, що з розвитком технологій, зі збільшенням ефективності на одну панель, той самий рівень пилу призводить до ще більших втрат енергії та подальших економічних збитків. Крім того, хоча осідання пилу може не розпізнаватися як несправність фотоелектричного модуля, це зрештою може призвести до скорочення терміну служби панелі. Дослідження [10], демонструє за допомогою моделювання, що втрати енергії у фотоелектричній системі через накопичення пилу можуть сягати 26,22% щороку в районах з несприятливими характеристиками. Дослідження забруднення в Чилі [11] показало, що навіть якщо у двох різних місцях рівень забруднення на день може бути порівняним (тобто, 0,6 % на день) на півночі (пустельна зона) щорічні

втрати енергії можуть сягати 39 %, тоді як у центральній зоні (з вищою кількістю опадів) це число зменшується до 7 %.

Загалом, виявлення та очищення невеликих та житлових фотоелектричних систем мало цікавлять, і це часто вважається додатковими витратами на фотоелектричних електростанціях [9]. Зазвичай частота очищення не є повністю встановленою; однак її можна економічно спланувати, коли вартість втрат енергії перевищує вартість очищення [12]. Багато власників сонячних електростанцій та компаній з експлуатації та технічного обслуговування виконують два очищення на рік, застосовуючи критерій для кожного випадку окремо, навіть незважаючи на те, що зараз доступні нові алгоритми для встановлення частоти очищення [13]. Явище «качиної кривої» в сонячних фотоелектричних системах повільно зменшується через збільшення встановлення BESS (систем безперебійного енергоспоживання). З огляду на цю тенденцію, продаж енергії за вищою ціною був би більш привабливим для власників електростанцій, і тоді забруднення стало б ще дорожчим, ніж фактичний сценарій.

Існує кілька методів автоматичного виявлення, здебільшого заснованих на штучному інтелекті [14, 15, 16, 17, 18], і дуже мало з них заснованих на звичайних алгоритмах [18, 19]. У роботі [19] запропонован алгоритм, заснований на колірному просторі CIELAB, який здатний визначати відсоток забруднення модуля, використовуючи зразок пилу та чисту панель. У цій роботі пропонується метод, заснований на алгоритмах, який генерує емпіричну модель для оцінки потужності, що виробляється рівномірно забрудненою фотоелектричною панеллю, на основі аналізу зображень. У першій частині алгоритм використовує штучний інтелект лише для обрізання та зміни форми зображень. Після цього створюється серія баз даних з ґрунтом з трьох різних місць розташування сонячних електростанцій: Ламберт (Луїзіана), Льянос-де-Потросо (Лондон) та Ло-Міранда (Ломон). Забруднення визначається та класифікується за допомогою каналу CIELAB b, а результати корелюють з виміряною потужністю та випромінюванням. Це створює калібрувальний вектор, який можна

використовувати для оцінки потужності від невідомого джерела. Цей метод може позитивно вплинути на продуктивність та термін служби сонячних панелей, слугуючи діагностичним інструментом для впровадження ефективних стратегій очищення.

2.2. Матеріали та методи

У цьому розділі описано матеріали та методи, що використовуються для розробки експериментальної системи, призначеної для рівномірного забруднення фотоелектричних панелей, з метою оцінки їхньої роботи в контрольованих умовах забруднення. Система включає проектування та конструкцію спеціалізованого обладнання для створення рівномірного забруднення на поверхні панелі, що дозволяє відтворювати сценарії деградації, спричинені накопиченням пилу. Для захоплення зображень використовується камера видимого спектру, яка забезпечує точні візуальні дані про панелі за різних умов забруднення. Ці зображення зберігаються та організовуються в наборі даних, спеціально розробленому для аналізу зниження потужності на основі рівня забруднення. Обробка зображень та вилучення відповідних ознак дозволяють розробити модель, призначену для оцінки потужності, що генерується сонячними панелями, з фотографії. Для досягнення цієї мети використовуються методи комп'ютерного зору та машинного навчання за допомогою інструментів обробки зображень.

Нижче детально описано матеріали, використані для будівництва системи, а також методи, що використовуються для створення бруду, отримання зображень та розробки набору даних, що забезпечує відтворюваність експериментів та надійність отриманих результатів.

2.2.1 Симулятор пилу

Щоб отримати забруднені фотоелектричні панелі з ґрунту з різних місць, ми створили симулятор забруднення на основі моделей інших дослідників [20, 21, 22]. Деякі ключові відмінності нашого методу симулятора забруднення полягають у тому, що він може працювати на відкритому повітрі та підтримує модуль розміром 62 см × 32 см, а оскільки пилозабірник зібраний окремо від симулятора, його можна налаштувати для підтримки більших модулів. На рисунку 2.1 показано концептуальну схему пристрою, метою якого є створення пилового забруднення, що осідає на поверхні фотоелектричної панелі. Обладнання використовується на відкритому повітрі, але в закритому просторі. Конструкція повинна бути достатньо міцною для роботи на відкритому повітрі, але водночас легкою для зручного транспортування. Вона виготовлена з алюмінієвих профілів і покрита жерстяними листами для запобігання впливу зовнішнього вітру. Фактичні показники пристрою представлені в Додатку А.




Рисунок 2.1. – Концептуальна схема пристрою-імітатора пилу. Ґрунт осідає в контейнері з ситом за допомогою садової ручної лопати; значна частина важкого пилу падає безпосередньо на дно конструкції, а легші частинки видаляються потоком повітря, що створюється вентиляторами. Коли вони стикаються з дефлектором, утворюється хмара пилу. Слід враховувати, що це відбувається всередині закритої конструкції

Пристрій має контейнер для ґрунту, який діє як сито з розміром пор 1,5 мм, в якому частинки ґрунту осідають у пил. Він використовує чотири 12-вольтові вентилятори для створення повітряного потоку, який ударає та витісняє найдрібніші частинки ґрунту, що падають із сита, створюючи потік пилу, який ударається об дефлектор. Він має похилу поверхню під кутом 40 градусів, що дозволяє витіснити сміття з ґрунту, полегшуючи його видалення. Це створює хмару пилу, яка осідає на поверхні фотоелектричної панелі, що призводить до однорідного розподілу частинок. Вентилятори мають імпульсно-широотно-модуляційне керування швидкістю та живляться від батарей, що забезпечує портативність та гнучкість використання в суворих умовах. Фотографії та розміри показано на рисунку A1 та рисунку A2 у Додатку А.

2.2.2. Прилади, що використовуються для збору даних

Під час експериментальних випробувань для запису ключових параметрів на момент зйомки фотографій використовувалися різні вимірювальні прилади: вимірювач опроміненості Fluke IRR1-SOL з роздільною здатністю 1 Вт/м², мультиметр Fluke 117 та камера дрона моделі Sony IMX477R (Sony Semiconductor Solutions Corporation, Ацугі-сі, Канагава, Японія) з роздільною здатністю 12,3 мегапікселя з 16-міліметровим телеоб'єктивом C-mount від CGL Electronics Co., Ltd. (Шеньчжень, Гуандун, Китай). Камера розташована приблизно на відстані 2 м у межах лінії видимості.

2.2.3. Налаштування обладнання в експериментальних випробуваннях

Для забезпечення відтворюваності експериментів випробування проводилися в контрольованому середовищі, розробленому для мінімізації

впливу зовнішніх факторів. Для стримування пилової хмари, що утворюється під час фази забруднення, використовувався замкнутий простір. Цей робочий простір ізолюваний рухомими панелями, що покривають як периметр, так і верхню частину, гарантуючи, що зовнішній вітер не заважатиме осадженню частинок пилу, таким чином досягаючи однорідного розподілу твердих частинок на фотоелектричній панелі. На рисунку 2 показано описану вище конструкцію з фотоелектричною панеллю всередині. Ліворуч від робочого простору розташований симулятор пилу разом із приладами для вимірювання сонячної радіації, напруги та струму. На рисунку 2 також показано камеру видимого світла, встановлену на кафедрі. Робоча станція має шість рухомих панелей, закритих по краях, зі знімними верхніми кришками, які використовуються під час фотографування.




Рисунок 2.2. – Реалізація та налаштування апаратного забезпечення для робочого простору розміром 120 см завширшки, 152 см завдовжки та 80 см заввишки

Випробування проводилися влітку в Південній півкулі на широті - 33.408162 та довготі -70.503075, в районі Лас-Кондес столичного регіону

Сантьяго, Чилі. Дні з ясным небом були обрані, щоб уникнути коливань сонячної радіації, спричинених хмарним покривом. Графік випробувань був з 11:00 до 14:00, коли сонячна радіація найбільш стабільна, а частота проєктованих тіней мінімізована. Максимальна радіація досягла 1060 Вт/м², тоді як у середньому досяг приблизно 975,22 Вт/м².

Для експериментів ми використовували полікристалічну панель потужністю 30 Вт (Ps30 enertik) та монокристалічну панель (SFM-29.8W) для остаточного тесту. Детальна інформація про модулі наведена в Додатку В. Панель була стратегічно розміщена в робочому просторі, забезпечуючи потрапляння прямих сонячних променів на її поверхню без перешкод від тіней або відблисків від стін замкнутого простору.

2.2.4. Методологія систематичного захоплення зображень

Процедура створення набору даних включає систематичну зйомку зображень сонячної панелі з різним рівнем забруднення, від найчистішого до найбільш забрудненого стану. Цей процес був розроблений для забезпечення контрольованого прогресу накопичення забруднення, що дозволяє подальшу кореляцію між рівнем забруднення та потужністю, що виробляється панеллю.

Протокол, що використовується для захоплення зображення, виглядає наступним чином:

- Підготовка системи забруднення: Частинки матеріалу вводяться в контейнер імітатора пилу.
- Ізоляція випробувального середовища: Корпус, в якому розташована сонячна панель, герметичний для запобігання перешкодам від зовнішніх повітряних потоків.
- Активація системи розсіювання: Вентилятори вмикаються для створення контрольованого руху пилу в робочому просторі.

- Розподіл твердих частинок: Сито активується для контрольованого розсіювання пилу, де дрібні частинки витісняються потоком повітря, який впливає на похилу поверхню, створюючи хмару зважених частинок.
- Час затвердіння: Система працює протягом 30 секунд, щоб забезпечити однорідне покриття твердими частинками.
- Осідання пилу: Вентилятори вимикаються, і система чекає ще 30 секунд, щоб зважені частинки повністю осіли на поверхні панелі.
- Вплив сонячної радіації: Верхня кришка корпусу знімається, що дозволяє прямим сонячним променям потрапляти на панель.
- Захоплення зображення: Фотографія панелі робиться за допомогою камери з роздільною здатністю 1600×1200 пікселів, що забезпечує стандартизовані умови освітлення.
- Вимірювання: миттєві значення струму та напруги реєструються разом із випромінюванням, в якому фіксується зображення.

ВИСНОВКИ ДО РОЗДІЛУ 2

У цьому дослідженні було створено серію наборів даних у контрольованих умовах, кожен з яких відповідав окремій експериментальній кампанії. Ці кампанії були ретельно розроблені для отримання зображень та електричних змінних фотоелектричних панелей, що зазнали різного ступеня забруднення поверхні. Набори даних відрізнялися один від одного, головним чином, походженням ґрунту, який використовувався в процесі забруднення фотоелектричних панелей. Збір кожного зразка ґрунту був ретельно виконаний з різних реальних сонячних електростанцій, що забезпечувало представлення умов забруднення з фізичним та колориметричним складом, специфічним для кожної ділянки. Відтепер ми називатимемо ці набори даних Ламберта (15 зображень), Міранди (10 зображень) та Потрозо (12 зображень), які представляють ґрунт з цих відповідних місць розташування електростанцій.

Кожен набір даних складається з зображень у форматі RGB, отриманих за контрольованих умов після нанесення ґрунту. У поєднанні з кожним зображенням було задокументовано часову залежність моменту захоплення зображення, а також значення струму короткого замикання (I_s c), напруга холостого ходу (V_o c), та падаюча радіація (G_m). Ця методологія дозволила пов'язати точне кількісне вимірювання генерованої потужності з кожним зображенням. Важливо зазначити, що кожне зображення було збережено у такому форматі відповідно до часу захоплення та відповідного набору даних: «LA_hour_minute.png» для зображення з набору даних Lambert, «LP_hour_minute.png» з набору даних Potroso та «LM_hour_minute.png» з набору даних Miranda.

РОЗДІЛ 3. ЕМПІРИЧНА МОДЕЛЬ

3.1. Оцінка стану на основі аналізу зображень

Після нашої попередньої роботи [19] ми використали колірний простір CIELAB для розробки емпіричної моделі для автоматичного виявлення ґрунту та оцінки виробництва електроенергії. Використання каналу *b* CIELAB особливо корисне для визначення стану пилу та чистоти у фотоелектричних панелях. Більшість панелей мають синій або темно-синій колір, тоді як пил зазвичай має коричневі або жовті відтінки, що забезпечує природне розмежування між цими двома станами.

Зображення набору даних були отримані на відкритому повітрі, що зробило необхідним сегментувати фотоелектричну панель від фону. Для цього ми використовуємо алгоритм комп'ютерного зору, який автоматично сегментує зображення за допомогою моделі YOLOv8 [23, 24]. Цей алгоритм був навчений з використанням нашого власного набору даних із зображеннями фотоелектричних панелей, позначеними вручну [25]. Слід зазначити, що це єдине використання штучного інтелекту в цій роботі. Після виконання висновку та успішної сегментації панелі застосовується алгоритм корекції перспективи. Нарешті, зображення змінюються на 2000×3500 px для керування роздільною здатністю, яка не затримує обробку.

Етапи обробки для налаштування моделі зображено на блок-схемі на рисунку 3. Спочатку слідує шлях чорної стрілки; для аналізу необхідно вибрати пунктирну лінію. По-перше, попередньо оброблені зображення перетворюються в CIELAB-*b*, і необхідно перевірити, чи зображення відповідають тенденції під час осідання забруднення. Вибір здійснюється за допомогою графіка, який пов'язує струм на кожному зображенні з його середнім значенням у каналі *b*. Очікується обернено пропорційна залежність: чим нижча сила струму (тобто чим більше забруднення), тим вище середнє значення в каналі *B*. Зразки, які не відповідають цій залежності, були відкинуті.




Рисунок 3.1. – Блок-схема алгоритму обробки зображень.

Спочатку Коефіцієнти необхідно отримати, слідуючи шляху чорних стрілок. Після встановлення ці значення можна застосувати до невідомого зображення, слідуючи пунктирним шляхом

Після фільтрації кривої вибираються зображення, що представляють кожен рівень забруднення. Оскільки відкладення ґрунту відбувається дуже поступово, з невеликою кількістю пилу, що додається на кожній ітерації, багато зображень виглядають досить схожими при аналізі за допомогою гістограм. Для перевірки згаданого вище порогового значення на основі гістограм було переглянуто коробкові діаграми п'яти вибраних зображень. Було встановлено, що перекриття міжквартильних діапазонів двох послідовних зображень не повинно перевищувати 80%. Якщо вищезазначена умова виконується,

визначаються порогові значення рівнів; в іншому випадку вибираються нові зразки, і процес повторюється. Цей крок встановлює граничні значення в каналі CIELAB, які обмежують рівні забруднення. Цей критерій буде розглянуто в розділі 3.2 з фактичними значеннями перекриття.

Щоб встановити кореляцію між забрудненими зображеннями та фактичною потужністю на момент зйомки, ми використовували матрицю, лінії якої побудовані з гістограм зображень (тут інтервали зведені до п'яти рівнів забруднення). Кожне зображення генерує вектор, що вказує на частку пікселів на кожному рівні забруднення, яка потім нормалізується до загальної кількості пікселів. Ми називатимемо ці вектори PV_{soiled} . Ці вектори потім організовуються в матрицю $(m \times n)$, де n позначає кількість рівнів забруднення, а m рядків – це PV_{soiled} вектори. Матриця, позначена як $M(m \times n)$, як очікується, апроксимує одиничну матрицю, де найбільше значення кожного вектора відповідає його заданому рівню. Нижче наведено приклад матриці для набору даних LA:

$$M_{5 \times 5} = \begin{pmatrix} PV_{soiled1} \\ PV_{soiled2} \\ PV_{soiled3} \\ PV_{soiled4} \\ PV_{soiled5} \end{pmatrix}, \quad M_{5 \times 5} = \begin{pmatrix} 0.56 & 0.19 & 0.06 & 0.05 & 0.12 \\ 0.20 & 0.28 & 0.11 & 0.14 & 0.24 \\ 0.02 & 0.15 & 0.17 & 0.18 & 0.45 \\ 0 & 0.03 & 0.08 & 0.26 & 0.6 \\ 0 & 0 & 0.01 & 0.09 & 0.83 \end{pmatrix} \quad (3.1)$$

де є тенденція позначати діагональ. Це буде пояснено далі.

Після побудови вищезгаданої матриці для кожного зразка генерується вектор-стовпець виміряної потужності. Рядки вектора тут представляють виміряну потужність, що відповідає відповідному зразку в матриці M розміром $m \times n$. Щоб правильно пов'язати вектор потужності з матрицею забруднення, необхідно нормалізувати обидва. Отже, вектор потужності нормалізується з використанням його максимального значення, яке відповідає найчистішій панелі та є першим вимірюванням.

Ще одним критичним фактором є радіація, яка навіть за умов ясного неба змінюється протягом дня через коефіцієнт повітряної маси (AM_0 , $AM_{1.5}$ тощо). Потім отримані значення потужності коригуються на основі опроміненості,

зафіксованої під час початкового запису зразка. Цей процес включає визначення опроміненості початкового зразка як базової, а потім коригування значень потужності інших відносно оригіналу. За допомогою цього калібрування, якщо рівень випромінювання збільшується або зменшується, потужність завжди відповідає початковому значенню. Це можливо лише у випадку рівномірного розподілу забруднення, що характерно для всіх підготовлених зразків.

Рівняння для оцінки потужності являє собою простий лінійний тренд, виражений наступним чином:

$$P_{adj} = P_m \cdot \frac{G_{ref}}{G_m}, \quad (3.2)$$

де P_m – виміряна потужність (Вт), G_m – виміряне випромінювання (Вт/м²), G_{ref} – опорне випромінювання (Вт/м²), та $P_{прил.}$ (Вт) – потужність, скоригована на еталонну опроміненість.

Зрештою, після отримання нормалізованої матриці M та степеня необхідно знайти модель множинної лінійної регресії, яка встановлює зв'язок між ними. Метою цього дослідження є визначення вектора (λ), що містить коефіцієнти, специфічні для кожного рівня забруднення. Коефіцієнти регресії визначаються шляхом заміни розрахункової потужності експериментально отриманими значеннями потужності. Згодом, шляхом розв'язання задачі щодо параметра λ , ми приходимо до наступного результату:

$$\lambda = M_{m \times n}^{-1} \cdot P_{n \times 1}. \quad (3.3)$$

Для застосування цієї моделі потрібен вектор забруднення забрудненої панелі. Цей вектор отримується з використанням меж CIELAB b для кожного з рівнів забруднення для створення вектора зображення. Щоб отримати оцінену потужність, цей вектор множиться на вектор i , нарешті, денормалізований базовим степенем P_{base} (Рівняння (2.4)). Для аналізу набору зображень процедура така ж, за винятком використання матриці M , що містить набір PV_{soiled} вектори (рівняння (3.5)):

$$P_{\text{estimate}} [\text{W}] = (PV_{\text{soiled}} \cdot \lambda) P_{\text{base}} [\text{W}], \quad (3.4)$$

$$P_{\text{estimate}} [\text{W}]_{m \times 1} = (\mathbf{M}_{m \times n} \cdot \lambda_{n \times 1}) P_{\text{base}} [\text{W}]. \quad (3.5)$$

Звичайно, це залежить від поглинання світла пилом над панеллю, тому ми досліджували три типи пилу, що надходить з різних місць розташування заводу. Мета полягає в тому, щоб знайти спільну тенденцію поглинання ґрунтом без необхідності визначення складу ґрунту. Важливо зазначити, що P_{base} базова потужність, пов'язана з PV_{soiled}

3.2. Аналіз даних

У цьому розділі ілюструється реалізація алгоритмів з використанням зображень з бази даних, створеної з ґрунту сонячної фотоелектричної електростанції Льянос-де-Потросо . Початкова процедура передбачає автоматичну сегментацію фотоелектричної панелі за допомогою алгоритму комп'ютерного зору, як показано на рисунку 3.24. Оригінальне захоплене зображення зображено на рисунку 3.2а, тоді як виявлення та ізоляцію панелі можна побачити на рисунку 3.2б . Модель демонструє високий ступінь ефективності в ідентифікації клітин, досягаючи приблизної ймовірності виявлення 94%. Після сегментації клітин будь-який піксель поза маскою сегментації визначається як нульове значення. Результат, у якому фон та рамка панелі видаляються, показано на зображенні рисунка 3.2с, оскільки фонові інформація не має значення для цього дослідження. Згодом перспектива сегментованого об'єкта коригується для нормалізації його форми за допомогою алгоритму корекції перспективи. Отримане зображення відображається на рисунку 3.2д . Ця процедура повторюється для кожного зображення в наборі даних, при цьому відповідна інформація фільтрується, щоб дозволити аналіз поведінки суб'єкта в спектрі CIELAB b .




Рисунок 3.2. – Висновок моделі YOLO: (a) оригінальне зображення без обробки, (b) виявлення та виділення панелі, (c) видалення фону та рамки панелі, та (d) кінцеве зображення з корекцією перспективи

Після сегментації всіх зображень та їх перетворення в b -простір CIELAB, відбираються певні зразки для представлення кожного з п'яти рівнів забруднення. Для досягнення цієї мети весь набір даних піддається оцінці. Зображення, які не відповідають тенденції залежності поточного значення b від каналу, згодом відкидаються, як зазначено в попередньому розділі. Для трьох використаних наборів даних жодне зображення не було видалено з набору даних Lambert, але 43,75% було відкинуто з набору даних Miranda та 17,65% з набору даних Potroso. Ці виключення зумовлені експериментальними невідповідностями, спричиненими рухами або зміщенням камери.

Зображення, відібрані для ілюстрації рівнів забруднення, потім піддаються аналізу. Цей аналіз включає візуалізацію гістограм та блокових діаграм кожного зразка з подальшою обробкою за допомогою емпіричної формули. Аналіз графіків на рисунку 2.2 встановлює інтервали, де кожне зображення концентрує найбільшу кількість пікселів, тим самим визначаючи діапазон, що відповідає кожному рівню забруднення. Як показано на рисунку 3.3а, представлено об'єднану гістограму зображень 1, 2 та 3. На рисунку 3.3б представлено гістограму зображень 3, 4 та 5, що ілюструє розподіл даних зображення та полегшує аналіз даних.






Рисунок 3.3. – (a) Порівняння гістограм для зображень 1, 2 та 3. (b) Порівняння гістограм для зображень 3, 4 та 5


Щоб переконатися, що зображення не мають однакового розподілу пікселів, відсотки перекриття між міжквартильними діапазонами послідовних зображень обчислюються за допомогою коробкових діаграм. Метою цієї частини є визначення статистично значущості спостережуваних відмінностей між ними. Для формалізації цього критерію було обчислено відсоток перекриття між міжквартильними діапазонами, отримавши діапазон від 39,1 % максимум 70,3 %. З цього ми можемо оцінити середнє перекриття для кожного набору, що призводить до 54,8 % для Лос-Анджелеса 55,1 % для ЛП, та 49,1 % для LM. З урахуванням цих результатів, поріг 80 % було встановлено максимальне перекриття. Якщо перекриття між двома послідовними зображеннями перевищує цю межу, пара вважається занадто схожою, і одне з них необхідно замінити, щоб забезпечити належний контраст між рівнями бруду. У цьому випадку, як видно на рисунку 3.4, було підтверджено, що вибрані зображення точно відображають кожен з рівнів бруду відповідно до встановленого порогу роздільної здатності. Важливо зазначити, що накопичення ґрунту не є лінійним, і це відображається в значеннях CIELAB для різних отриманих рівнів ґрунту. Наприклад, межі для набору даних LA такі (-37,1, -18,0, -14,2, -12,1, -9,1, 22,9). Ці межі отримані безпосередньо з порівняння коробчастих діаграм та гістограм (див. Рисунок 3.4)




(a)




(b)




(c)



(d)



(e)



(f)

Рисунок 3.4. (a) Коробчасті діаграми LA, (b) відсоток перекриття LA, (c) коробкові діаграми LP, (d) відсоток перекриття LP, (e) коробкові діаграми LM та (f) відсоток перекриття LM

ВИСНОВКИ ДО РОЗДІЛУ 3

Після перевірки цього кроку рівняння (3.3) застосовується для зв'язку інформації, що міститься на зображеннях п'яти зразків, відповідно до попередньо визначених інтервалів, з відповідною потужністю для кожного з них. Потім значення λ для кожного набору даних отримано. Результати цього кроку показано в рівнянні (3.6):

$$\begin{aligned}\lambda_{LA} &= (1.0229 \quad 1.1976 \quad 0.9053 \quad 1.0828 \quad 0.6067), \\ \lambda_{LP} &= (1.0204 \quad 1.1008 \quad 0.6931 \quad 1.5554 \quad 0.6213), \\ \lambda_{LM} &= (0.9899 \quad 1.0250 \quad 1.2803 \quad 0.7243 \quad 0.8086).\end{aligned}\quad (3.6)$$

Після отримання коефіцієнтів регресії, для оцінки потужності нового зображення або набору даних можна використовувати рівняння (3.4) або (3.5). Для виконання цієї оцінки достатньо отримати вектор, що містить інформацію про пікселі зображення, потужність якого потрібно оцінити. Важливо зазначити, що для невідомого набору даних або зображення потрібен рівень чистоти.

РОЗДІЛ 4. АНАЛІЗ РЕЗУЛЬТАТІВ ДОСЛІДЖЕННЯ

4.1. Оцінка точності наборів даних – зображення одного й того ж набору даних

Початковий аналіз включав оцінку точності оцінки потужності зображень зі спільного набору даних, включаючи ті, що використовувалися для отримання λ вектор. Ця оцінка полягала в оцінці потужності зображень з того самого набору даних, а потім оцінці потужності зображень з інших наборів даних.

Результати, отримані з набору даних Ламберта, вказують на високий ступінь точності оцінки потужності при застосуванні до власного набору даних (Рисунок 4.1a). Середня похибка оцінки відповідає 1,14 %, що вказує на високу точність відповідності між оціненою потужністю та фактичною потужністю. З іншого боку, смуги похибок демонструють більший діапазон, ніж точна оцінка. Це пояснюється тим, що смуги похибок виникли через помилку в оцінці λ , що буде розглянуто пізніше. На рисунку 4.1b показано потужність набору даних Ламберта, оцінену з використанням інших λ s. У цьому випадку розбіжності більші із середньою похибкою 9,89 % використовуючи ЛМ λ і 3,46 % використання LP λ .

Оцінка набору даних Miranda з використанням його власного λ , показано на рисунку 4.1 c. У цьому випадку спостерігається розбіжність для перших зображень (які мають менше забруднення) та чудова відповідність для зображень, які мають більше забруднення. У цьому випадку середня похибка оцінки відповідає 3,05 %. На рисунку 4.1d показано оцінку набору даних LM за допомогою LA λ та ЛП λ , в результаті чого 3,38 % і 2,37 % помилки відповідно.

Зрештою, емпіричні результати, отримані з вибірок набору даних Potroso, показані на рисунку 4.1 e, f. Самооцінка демонструє чудову відповідність з похибкою 1,17 %, тоді як перехресна оцінка призвела до певного зміщення. Похибка оцінки потужності за допомогою LA λ був 5,08 % і з Л.М. λ був 2,32 %.

Загалом, результати хороші, за винятком кількох випадків. Однак, Потрозо λ Вектор безсумнівно показав кращі результати як у самооцінці, так і в перехресній оцінці. Порівняння всіх середніх помилок представлено в таблиці 4.1.




Рисунок 4.1. – Оцінка потужності всіх наборів даних за допомогою розробленої моделі. (a) Набір даних LA, оцінений за допомогою LA λ , (b) Набір даних LA, оцінений за допомогою LP λ та Л.М. λ , (c) Набір даних LM, оцінений за допомогою LM λ , (d) Набір даних LM, оцінений за допомогою LP λ та Лос-Анджелес λ , (e) Набір даних LP, оцінений за допомогою LP λ , та (f) набір даних LP, оцінений за допомогою LM λ та Лос-Анджелес λ

Таблиця 4.1. – Порівняння середніх помилок усіх наборів даних

	Лос-Анджелес	ЛМ	ЛП
Самооцінка (%)	1.14	3.05	1.17
Перехресна оцінка (%)	3.38	9.89	3.46
Перехресна оцінка (%)	5.08	2.32	2.37

Щодо планок похибки, вони були розраховані, припускаючи, що матриця M може бути одиничною матрицею. Це, звичайно, ідеальний сценарій, де кожне зображення має непересічний розподіл гістограми, який явно не є реальним. Тим не менш, хоча планки похибки досить значні, ми вважаємо, що ця похибка більше відображає реальну похибку. Це трапляється, коли гістограма сегментована на певні рівні, що ускладнює її кількісну оцінку. Ігноруючи сегментацію, існує ще одна похибка, яка сприяє, що є експериментальною похибкою вимірювання потужності, яка є надзвичайно низькою.

4.2. Тестування моделі

Щоб оцінити ефективність векторів на зображеннях, що відрізняються від оригіналу, було створено новий набір даних, що містить різноманітні характеристики, включаючи інший модуль та пил, зібраний з університетського кампусу. Новий фотоелектричний модуль – це...29.8. Монокристалічний модуль W_p з розрахунковим коефіцієнтом заповнення 0,778. Новий набір даних, який ми називаємо Перевіркою або VAL, складається з чотирьох зображень сонячної панелі з різним ступенем забруднення. Дані журналу представлені в таблиці 4.2, де рівень забруднення 1 відповідає повністю чистій панелі, а рівень забруднення 4 – найбрудніший.

Таблиця 4.2. – Дані нового набору даних панелі

Рівень забруднення	Зображення	G_m (Вт/м ²)	I_{sc} [A]	V_{oc} [В]	Π_{adj} [Вт]
1	11 _ 48	732	1.392	19,85	21.497
2	11 _ 53	770	1.357	19,69	19.760
3	11 _ 57	778	1.350	19.80	19.570
4	12 _ 05	782	1.380	19.57	19.667

Оскільки цей набір даних містить абсолютно різні зображення, після сегментації та корекції перспектив процедура відповідає пунктирній лінії, показаній на рисунку 3. Єдине застереження полягає в тому, що чистий діапазон необхідно скоригувати відповідно до діапазону інших наборів даних. Це пояснюється тим, що вектори були розраховані за допомогою іншої панелі, і, як наслідок, мінімальне значення синього в CIELAB- b відрізняється. Рівняння (3.4) використовується для оцінки оцінки потужності при застосуванні до нових зображень. Ця оцінка дозволяє провести порівняльний аналіз, що представляє уявлення про характеристики продуктивності кожного вектора коефіцієнтів. Результати цього аналізу представлені на рисунку 4.2.




Рисунок 4.2. – Оцінка потужності відповідно до вектора коефіцієнтів регресії з різних наборів даних

Нарешті, було розраховано точність оцінки потужності для кожного зображення, отримавши середню точність 9,60 % для вектора Llanos de Potroso, 7,05 % для Ло Міранди, та 7,28 % для вектора Ламберта. Усі відносні похибки для цього набору даних можна побачити в таблиці 3. Варто зазначити, що оцінки показують похибку приблизно 10 % реальної потужності, навіть з зовсім іншим модулем та іншим типом ґрунту. Очевидно, що ґрунт може поглинати більшу кількість випромінювання, що призводить до більшої невідповідності між розрахунковою та фактичною потужністю.

Таблиця 4.3. – Відносні похибки оцінки потужності для набору даних VAL.

	1	2	3	4	Середній
ЛА (%)	0,51	9.57	9.81	9.25	7.28
ЛМ (%)	0,25	10.84	8.88	8.23	7.05
ЛП (%)	2.53	12.24	12.12	11.51	9.06

ВИСНОВКИ ДО РОЗДІЛУ 4

У розділі представлені експериментальні результати, отримані шляхом застосування запропонованого методу для оцінки потужності, що генерується фотоелектричними панелями за різних умов забруднення. Представлено конкретні результати, отримані для кожного набору даних, включаючи реальні та розрахункові значення потужності, а також досягнуті рівні точності. Крім того, проведено ретельний аналіз результатів при застосуванні векторів регресії, згенерованих у зовнішніх наборах даних, для оцінки точності та узгодженості прогнозів, зроблених запропонованою моделлю.

ВИСНОВКИ Й РЕКОМЕНДАЦІЇ

Забезпечення енергетичної безпеки є критично важливим завданням сучасної енергетики.

У цій роботі представлено емпіричну модель, яка оцінює втрати потужності у фотоелектричній (ФЕ) панелі, спричинені забрудненням, використовуючи лише візуальні дані із зображень як забруднених, так і чистих панелей. Данний підхід дозволяє уникнути необхідності використання великих наборів даних машинного навчання, використовуючи фізично заснований метод обробки зображень, який використовує аналіз колірного простору CIELAB разом із каліброваною регресійною моделлю. Результати показують, що при тестуванні на власному наборі даних модель досягає високої точності з похибками оцінки потужності нижче 3%. Перехресне тестування наборів даних – з використанням ґрунту з різних географічних місць – дає діапазон похибок від 3% до 10%. Навіть у найскладнішому сценарії, з абсолютно різним модулем та типом ґрунту, модель зберігає середню похибку оцінки близько 10%. Це підтверджує широку застосовність підходу, що робить його перспективним інструментом для неінвазивної діагностики потужності та дистанційного моніторингу ФЕ систем, особливо в посушливих регіонах, де забруднення є значною проблемою.

Незважаючи на певні експериментальні обмеження, включаючи порушення навколишнього середовища, зміщення камери та мінливість вимірювань, наш метод добре працює з невеликим набором зображень (близько 30 зображень), на відміну від моделей глибокого навчання, які зазвичай вимагають тисяч маркованих зображень (принаймні 5000). Це значно знижує бар'єр для його розгортання на реальних сонячних електростанціях.

Майбутня робота включатиме інтеграцію температурної компенсації з термопарами на задній панелі для покращення оцінок потужності на основі напруги, розширення моделі для охоплення різних моделей забруднення та технологій панелей, а також розробку зручного застосунку для діагностики на місці або за допомогою дронів.

Додаток А

На рисунках А1 а–с представлено три різні зображення пилозбірної станції, тоді як на рисунку А1 d ілюструється її розміри. На рисунку А2 а зображено акумулятор та регулятор швидкості вентилятора, а на рисунку А2 b наведено схему взаємоз'єднання між пристроями.




Рисунок А1. Вигляд пиловловлювальної станції: (а) зверху, (б) спереду, (с) збоку та (d) розміри.




Рисунок А2. Керування вентилятором: (а) фотографія пристроїв; (б) схема підключення

Додаток Б

У цьому додатку ми надаємо технічні дані модулів, що використовуються в цьому дослідженні

Таблиця Б1. Технічні дані модулів

	Ps30 Енертік	SFM-29,8 Вт
Максимальна потужність (P _{Max})	30 Вт	29,8 Вт
Напруга при P _{Max} (V _{mp})	18,54 В	18,1 В
Струм при P _{Max} (I _{mp})	1,62 А	1,64 А
Напруга холостого ходу (V _{oc})	22,68 В	21,6 В
(Струм короткого замикання (I _{sc}))	1,76 А	1,8 А

СПИСОК ПОСИЛАНЬ

1. Конституція України: Конституція України; Верховна Рада України від 28.06.1996 № 254к/96–ВР // База даних «Законодавство України» / 45 Верховна Рада України. URL: <https://zakon.rada.gov.ua/go/254%D0%BA/96-%D0%B2%D1%80>.
2. Омельченко Володимир. Сектор відновлюваної енергетики України до, під час та після війни. Центр Разумкова. 2022. URL: <https://razumkov.org.ua/statti/sektor-vidnovlyuvanoji-energetyky-ukrayiny-do-pidchas-ta-pislya-viyny>.
3. Про Концепцію діяльності органів виконавчої влади у забезпеченні енергетичної безпеки України : Постанова Кабінету Міністрів України від 19.01.1998 № 48 URL: <https://zakon.rada.gov.ua/go/48-98-%D0%BF/>
4. Про нафту і газ : Закон України від 12.07.2001 № 2665–III URL: <https://zakon.rada.gov.ua/go/2665-14>.
5. Про Національний план дій з енергоефективності на період до 2030 року : Розпорядження Кабінету Міністрів України; План, Заходи від 12.2021 № 1803–р // База даних «Законодавство України» / Верховна Рада України. URL: <https://zakon.rada.gov.ua/go/1803-2021-%D1%80>.
6. Про Національну комісію, що здійснює державне регулювання у сферах енергетики та комунальних послуг : Закон України від 22.09.2016 № 1540–VIII // База даних «Законодавство України» / Верховна Рада України. URL: <https://zakon.rada.gov.ua/go/1540-19>.
7. Про ринок електричної енергії : Закон України від 13.04.2017 № 2019–VIII URL: <https://zakon.rada.gov.ua/go/2019-19>.
8. Про схвалення Концепції впровадження “розумних мереж” в Україні до 2035 року : Розпорядження Кабінету Міністрів України; Концепція, План, Заходи від 14.10.2022 № 908–р // База даних «Законодавство України» / Верховна Рада України. URL: <https://zakon.rada.gov.ua/go/908-2022-%D1%80> .

9. Про схвалення Плану розвитку системи передачі на 2021–2030 роки : Постанова; Нацком.енергетики, ком.послуг від 20.01.2021 № 57 // База даних «Законодавство України» / Верховна Рада України. URL: <https://zakon.rada.gov.ua/go/v0057874-21>.
10. Паливно–енергетичний комплекс України на порозі третього тисячоліття [За заг. ред. А.К. Шидловського, М.П. Ковалка]. – К.: УЕЗ, – 2001. – 398 с.
11. Alshareef, M. A Comprehensive Review of the Soiling Effects on PV Module Performance. *IEEE Access* 2023, 11, 134623–134651. [CrossRef]
12. Borah, P.; Micheli, L.; Sarmah, N. Analysis of Soiling Loss in Photovoltaic Modules: A Review of the Impact of Atmospheric Parameters, Soil Properties, and Mitigation Approaches. *Sustainability* 2023, 15, 16669. [CrossRef]
13. Jaszczur, M.; Teneta, J.; Styszko, K.; Hassan, Q.; Burzyńska, P.; Marcinek, E.; Łopian, N. The field experiments and model of the natural dust deposition effects on photovoltaic module efficiency. *Environ. Sci. Pollut. Res.* 2019, 26, 8402–8417. [CrossRef] [PubMed]
14. Ilse, K.; Figgis, B.; Naumann, V.; Hagendorf, C.; Bagdahn, J. Fundamentals of soiling processes on photovoltaic modules. *Renew. Sustain. Energy Rev.* 2018, 98, 239–254. [CrossRef]
15. Conceição, R.; González-Aguilar, J.; Alami Merrouni, A.; Romero, M. Soiling effect in solar energy conversion systems: A review. *Renew. Sust. Energ. Rev.* 2022, 162, 112434. [CrossRef]
16. Gholami, A.; Khazaei, I.; Eslami, S.; Zandi, M.; Akrami, E. Experimental investigation of dust deposition effects on photo-voltaic output performance. *Sol. Energy* 2018, 159, 346–352.
17. Gupta, V.; Sharma, M.; Kumar Pachauri, R.; Dinesh Babu, R. Comprehensive review on effect of dust on solar photovoltaic system and mitigation techniques. *Sol. Energy* 2019, 191, 596–622. [CrossRef]
18. Khodakaram-Tafti, A.; Yaghoubi, M. Experimental study on the effect of dust deposition on photovoltaic performance at various tilts in semi-arid environment. *Sustain. Energy Technol. Assessments* 2020, 42, 100822.

19. Soiling losses–Impact on the Performance of Photovoltaic Power Plants; Jahn, U., Ed.; Report IEA-PVPS T13-21:2022; The International Energy Agency (IEA): Paris, France, 2022.
20. Jamil, W.; Rahman, H.; Shaari, S.; Mat Desa, K. Modeling of Soiling Derating Factor in Determining Photovoltaic Outputs. *IEEE J. Photovolt.* 2020, 10, 1417–1423. [CrossRef]
21. Cordero, R.R.; Damiani, A.; Laroze, D.; MacDonell, S.; Jorquera, J.; Sepúlveda, E.; Feron, S.; Llanillo, P.; Labbe, F.; Carrasco, J.; et al. Effects of soiling on photovoltaic (PV) modules in the Atacama Desert. *Sci. Rep.* 2018, 8, 13943. [CrossRef] [PubMed]
22. Cristaldi, L.; Faifer, M.; Rossi, M.; Catelani, M.; Ciani, L.; Dove, E.; Jerace, S. Economical evaluation of PV system losses due to the dust and pollution. In *Proceedings of the 2012 IEEE International Instrumentation and Measurement Technology Conference Proceedings*, Graz, Austria, 13–16 May 2012; pp. 614–618.
23. Tasmim, T.; Miran - Ul - Hasan Sajoy, S.M.; Sajjad, R.; Khan, M. Automatic cleaning suggestion adapting to real-time soiling status of solar farms. *Sol. Energy* 2024, 282, 112940. [CrossRef]
24. Cao, Y.; Pang, D.; Yan, Y.; Jiang, Y.; Tian, C. A photovoltaic surface defect detection method for building based on deep learning. *J. Build. Eng.* 2023, 70, 106375. [CrossRef]
25. Cruz-Rojas, T.; Franco, J.; Hernandez-Escobedo, Q.; Ruiz-Robles, D.; Juarez-Lopez, J. A novel comparison of image semantic segmentation techniques for detecting dust in photovoltaic panels using machine learning and deep learning. *Renew. Energy* 2023, 217, 119126. [CrossRef]
26. Fang, M.; Qian, W.; Qian, T.; Bao, Q.; Zhang, H.; Qiu, X. DGImNet: A deep learning model for photovoltaic soiling loss estimation. *Appl. Energy* 2024, 376, 124335. [CrossRef]

27. Evstatiev, B.I.; Trifonov, D.T.; Gabrovska-Evstatieva, K.G.; Valov, N.P.; Mihailov, N.P. PV Module Soiling Detection Using Visible Spectrum Imaging and Machine Learning. *Energies* 2024, 17, 5238. [CrossRef]
28. Fan, S.; Wang, X.; Wang, Z.; Sun, B.; Zhang, Z.; Cao, S.; Zhao, B.; Wang, Y. A novel image enhancement algorithm to determine the dust level on photovoltaic (PV) panels. *Renew. Energy* 2022, 201, 172–180. [CrossRef]
29. Funes, G.; Peters, E.; Delpiano, J. Using Image Analysis Techniques for Dust Detection Over Photovoltaic Panels. *ASME. J. Sol. Energy Eng.* 2025, 147, 041006. [CrossRef]
30. Muñoz-García, M.A.; Fouris, T.; Pilat, E. Analysis of the soiling effect under different conditions on different photovoltaic glasses and cells using an indoor soiling chamber. *Renew. Energy* 2021, 163, 1560–1568. [CrossRef]
31. Hussain, n.; Shahzad, N.; Yousaf, T.; Waqas, A.; Hussain Javed, A.; Khan, S.; Ali, M.; Liaquat, R. Designing of homemade soiling station to explore soiling loss effects on PV modules. *Sol. Energy* 2021, 225, 624–633. [CrossRef]
32. Fan, S.; Wang, Y.; Cao, S.; Sun, T.; Liu, P. A novel method for analyzing the effect of dust accumulation on energy efficiency loss in photovoltaic (PV) system. *Energy* 2021, 234, 121112. [CrossRef]
33. Ali, M.L.; Zhang, Z. The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection. *Computers* 2024, 13, 336. [CrossRef]
34. Cheng, S.; Chen, L.; Yang, K. DGSS-YOLOv8s: A Real-Time Model for Small and Complex Object Detection in Autonomous Vehicles. *Algorithms* 2025, 18, 358. [CrossRef]
35. Francois Brunel. FONDEF-Segmentación Celdas. 2024. Available online: <https://app.roboflow.com/fondefpaneles/fondefsegmentacion-celdas/1> (accessed on 5 May 2025).
36. Silverman, T.J.; Mansfield, L.; Repins, I.; Kurtz, S. Damage in Monolithic Thin-Film Photovoltaic Modules Due to Partial Shade. *IEEE J. Photovolt.* 2016, 6, 1333–1338. [CrossRef]

37. Paul, D.I. Dust Deposition on Photovoltaic Modules: Its Effects on Performance. In *The Effects of Dust and Heat on Photovoltaic Modules: Impacts and Solutions*; Springer: Berlin/Heidelberg, Germany, 2022; pp. 3–46.
38. Al Siyabi, I.; Al Mayasi, A.; Al Shukaili, A.; Khanna, S. Effect of Soiling on Solar Photovoltaic Performance under Desert Climatic Conditions. *Energies* 2021, 14, 659. [CrossRef]
39. Nalamwar, H.S.; Ivanov, M.A.; Baidali, S.A. Automated Intelligent Monitoring and the Controlling Software System for Solar Panels. *J. Phys. Conf. Ser.* 2017, 803, 012107. [CrossRef]
40. Kumar, N.M.; Sudhakar, K.; Samykano, M.; Jayaseelan, V. On the Technologies Empowering Drones for Intelligent Monitoring of Solar Photovoltaic Power Plants. *Procedia Comput. Sci.* 2018, 133, 585–593. [CrossRef]
41. Tina, G.M.; Cosentino, F.; Ventura, C. Monitoring and Diagnostics of Photovoltaic Power Plants. In *Renewable Energy in the Service of Mankind*; Springer International Publishing: Cham, Switzerland, 2016; Volume II, pp. 505–516.
42. Coleman, A.; Zalewski, J. Intelligent Fault Detection and Diagnostics in Solar Plants. In *Proceedings of the 6th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems*, Prague, Czech Republic, 15–17 September 2011; IEEE: Piscataway, NJ, USA, 2011; pp. 948–953.
43. Beránek, V.; Olšan, T.; Libra, M.; Poulek, V.; Sedláček, J.; Dang, M.-Q.; Tyukhov, I. New Monitoring System for Photovoltaic Power Plants' Management. *Energies* 2018, 11, 2495. [CrossRef]
44. Libra, M.; Daneček, M.; Lešetický, J.; Poulek, V.; Sedláček, J.; Beránek, V. Monitoring of Defects of a Photovoltaic Power Plant Using a Drone. *Energies* 2019, 12, 795. [CrossRef]
45. Jayas, D.S.; Paliwal, J.; Visen, N.S. Review Paper (AE—Automation and Emerging Technologies). *J. Agric. Eng. Res.* 2000, 77, 119–128. [CrossRef]
46. Sietsma, J.; Dow, R.J.F. Creating Artificial Neural Networks That Generalize. *Neural Netw.* 1991, 4, 67–79. [CrossRef]

47. Sarle, W.S. Neural networks and statistical models. In Proceedings of the Nineteenth Annual SAS Users Group International Conference, Dallas, TX, USA, 10–13 April 1994; SAS Institute Inc.: Cary, NC, USA, 1994; pp. 1538–1550.
48. Kalogirou, S.A. Artificial Neural Networks in Renewable Energy Systems Applications: A Review. *Renew. Sustain. Energy Rev.* 2001, 5, 373–401. [CrossRef]
49. Kalogirou, S.A. Applications of Artificial Neural-Networks for Energy Systems. *Appl. Energy* 2000, 67, 17–35. [CrossRef]
50. Mo, K.; Lee, S.J.; Seong, P.H. A Dynamic Neural Network Aggregation Model for Transient Diagnosis in Nuclear Power Plants. *Prog. Nucl. Energy* 2007, 49, 262–272. [CrossRef]
51. Guo, Y.; Gong, C.; Zeng, H.-Y. The Application of Artificial Neural Network in Nuclear Energy. In Proceedings of the 2010 International Conference on Machine Learning and Cybernetics, Qingdao, China, 11–14 July 2010; IEEE: Piscataway, NJ, USA, 2010; pp. 1244–1248.
52. Ferrero Bermejo, J.; Gómez Fernández, J.F.; Olivencia Polo, F.; Crespo Márquez, A. A Review of the Use of Artificial Neural Network Models for Energy and Reliability Prediction. A Study of the Solar PV, Hydraulic and Wind Energy Sources. *Appl. Sci.* 2019, 9, 1844. [CrossRef]
53. El-Abbasy, M.S.; Senouci, A.; Zayed, T.; Mirahadi, F.; Parvizsedghy, L. Artificial Neural Network Models for Predicting Condition of Offshore Oil and Gas Pipelines. *Autom. Constr.* 2014, 45, 50–65. [CrossRef]
54. Tao, X.; Zhang, D.; Wang, Z.; Liu, X.; Zhang, H.; Xu, D. Detection of Power Line Insulator Defects Using Aerial Images Analyzed with Convolutional Neural Networks. *IEEE Trans. Syst. Man Cybern. Syst.* 2020, 50, 1486–1498. [CrossRef]
55. Schlechtingen, M.; Ferreira Santos, I. Comparative Analysis of Neural Network and Regression Based Condition Monitoring Approaches for Wind Turbine Fault Detection. *Mech. Syst. Signal Process.* 2011, 25, 1849–1875. [CrossRef]

56. Movsessian, A.; García Cava, D.; Tcherniak, D. An Artificial Neural Network Methodology for Damage Detection: Demonstration on an Operating Wind Turbine Blade. *Mech. Syst. Signal Process.* 2021, 159, 107766. [CrossRef]
57. Munawar, H.S.; Ullah, F.; Qayyum, S.; Khan, S.I.; Mojtahedi, M. UAVs in Disaster Management: Application of Integrated Aerial Imagery and Convolutional Neural Network for Flood Detection. *Sustainability* 2021, 13, 7547. [CrossRef]
58. Valdez, D.B.; Godmalin, R.A.G. A Deep Learning Approach of Recognizing Natural Disasters on Images Using Convolutional Neural Network and Transfer Learning. In *Proceedings of the International Conference on Artificial Intelligence and Its Applications*, EL-Oued, Algeria, 28–30 September 2021; ACM: New York, NY, USA, 2021; pp. 1–7.
59. Huerta Herraiz, Á.; Pliego Marugán, A.; García Márquez, F.P. Photovoltaic Plant Condition Monitoring Using Thermal Images Analysis by Convolutional Neural Network-Based Structure. *Renew. Energy* 2020, 153, 334–348. [CrossRef]
60. Haidari, P.; Hajiahmad, A.; Jafari, A.; Nasiri, A. Deep Learning-Based Model for Fault Classification in Solar Modules Using Infrared Images. *Sustain. Energy Technol. Assess.* 2022, 52, 102110. [CrossRef]
61. Sohani, A.; Sayyaadi, H.; Miremadi, S.R.; Samiezadeh, S.; Doranehgard, M.H. Thermo-Electro-Environmental Analysis of a Photovoltaic Solar Panel Using Machine Learning and Real-Time Data for Smart and Sustainable Energy Generation. *J. Clean. Prod.* 2022, 353, 131611. [CrossRef]
62. Alajmi, M.; Aljasem, O.; Ali, N.; Alqurashi, A.; Abdel-Qader, I. Fault Detection and Localization in Solar Photovoltaic Arrays Framework: Hybrid Methods of Data-Analysis and a Network of Voltage-Current Sensors. In *Proceedings of the 2018 IEEE International Conference on Electro/Information Technology (EIT)*, Rochester, MI, USA, 3–5 May 2018; IEEE: Piscataway, NJ, USA, 2018; pp. 404–410.

63. Samara, S.; Natsheh, E. Intelligent Real-Time Photovoltaic Panel Monitoring System Using Artificial Neural Networks. *IEEE Access* 2019, 7, 50287–50299. [CrossRef]
64. Hu, Y.; Zhang, J.; Cao, W.; Wu, J.; Tian, G.Y.; Finney, S.J.; Kirtley, J.L. Online Two-Section PV Array Fault Diagnosis with Optimized Voltage Sensor Locations. *IEEE Trans. Ind. Electron.* 2015, 62, 7237–7246. [CrossRef]
65. Chine, W.; Mellit, A.; Lughi, V.; Malek, A.; Sulligoi, G.; Massi Pavan, A. A Novel Fault Diagnosis Technique for Photovoltaic Systems Based on Artificial Neural Networks. *Renew. Energy* 2016, 90, 501–512. [CrossRef]
66. Lopez-Guede, J.M.; Ramos-Hernanz, J.A.; Zulueta, E.; Fernandez-Gamiz, U.; Oterino, F. Systematic Modeling of Photovoltaic Modules Based on Artificial Neural Networks. *Int. J. Hydrogen Energy* 2016, 41, 12672–12687. [CrossRef]
67. Ali, R.; Kang, D.; Suh, G.; Cha, Y.-J. Real-Time Multiple Damage Mapping Using Autonomous UAV and Deep Faster Region-Based Neural Networks for GPS-Denied Structures. *Autom. Constr.* 2021, 130, 103831. [CrossRef]
68. Ayoub, N.; Schneider-Kamp, P. Real-Time On-Board Deep Learning Fault Detection for Autonomous UAV Inspections. *Electronics* 2021, 10, 1091. [CrossRef]
69. Xun, D.T.; Lim, Y.L.; Srigrarom, S. Drone Detection Using YOLOv3 with Transfer Learning on NVIDIA Jetson TX2. In *Proceedings of the 2021 Second International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics (ICA-SYMP)*, Bangkok, Thailand, 20–22 January 2021; IEEE: Piscataway, NJ, USA, 2021; pp. 1–6.
70. Chen, Y.M.; Dong, L.; Oh, J.-S. Real-Time Video Relay for UAV Traffic Surveillance Systems Through Available Communication Networks. In *Proceedings of the 2007 IEEE Wireless Communications and Networking Conference*, Hong Kong, China, 11–15 March 2007; pp. 2608–2612.
71. Pereira, F.C.; Pereira, C.E. Embedded Image Processing Systems for Automatic Recognition of Cracks Using UAVs. *IFAC Pap. Online* 2015, 48, 16–21. [CrossRef]

72. Halawa, H.; Abdelhafez, H.A.; Boktor, A.; Ripeanu, M. NVIDIA Jetson Platform Characterization. In Proceedings of the 23rd International Conference on Parallel and Distributed Computing, Santiago de Compostela, Spain, 28 August–1 September 2017; pp. 92–105.
73. Suzen, A.A.; Duman, B.; Sen, B. Benchmark Analysis of Jetson TX2, Jetson Nano and Raspberry PI Using Deep-CNN. In Proceedings of the 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA), Ankara, Turkey, 26–28 June 2020; IEEE: Piscataway, NJ, USA, 2020; pp. 1–5.
74. Bokovoy, A.; Muravyev, K.; Yakovlev, K. Real-Time Vision-Based Depth Reconstruction with NVidia Jetson. In Proceedings of the 2019 European Conference on Mobile Robots (ECMR), Prague, Czech Republic, 4–6 September 2019; IEEE: Piscataway, NJ, USA, 2019; pp. 1–6.
75. Zoev, I.V.; Markov, N.G.; Ryzhova, S.E. Intelligent Computer Vision System for Unmanned Aerial Vehicles for Monitoring Technological Objects of Oil and Gas Industry. *Bull. Tomsk Polytech. Univ. Geo Assets Eng.* 2019, 330, 34–49. [CrossRef]
76. Aposporis, P. Object Detection Methods for Improving UAV Autonomy and Remote Sensing Applications. In Proceedings of the 2020 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM), The Hague, The Netherlands, 7–10 December 2020; IEEE: Piscataway, NJ, USA, 2020; pp. 845–853.
77. Ampatzidis, Y.; Partel, V.; Costa, L. Agrovie: Cloud-Based Application to Process, Analyze and Visualize UAV-Collected Data for Precision Agriculture Applications Utilizing Artificial Intelligence. *Comput. Electron. Agric.* 2020, 174, 105457. [CrossRef]
78. Russakovsky, O.; Deng, J.; Su, H.; Krause, J.; Satheesh, S.; Ma, S.; Huang, Z.; Karpathy, A.; Khosla, A.; Bernstein, M.; et al. ImageNet Large Scale Visual Recognition Challenge. *Int. J. Comput. Vis.* 2015, 115, 211–252. [CrossRef]

79. Zhang, Y.; Yuan, Y.; Feng, Y.; Lu, X. Hierarchical and Robust Convolutional Neural Network for Very High-Resolution Remote Sensing Object Detection. *IEEE Trans. Geosci. Remote Sens.* 2019, 57, 5535–5548. [CrossRef]
80. Wang, Z.; Liu, J. A Review of Object Detection Based on Convolutional Neural Network. In *Proceedings of the 2017 36th Chinese Control Conference (CCC)*, Dalian, China, 26–28 July 2017; IEEE: Piscataway, NJ, USA, 2017; pp. 11104–11109.
81. Fang, W.; Wang, L.; Ren, P. Tinier-YOLO: A Real-Time Object Detection Method for Constrained Environments. *IEEE Access* 2020, 8, 1935–1944. [CrossRef]
82. Dai, J.; Li, Y.; He, K.; Sun, J. R-FCN: Object Detection via Region-Based Fully Convolutional Networks. In *Proceedings of the 30th Annual Conference on Neural Information Processing Systems 2016*, Barcelona, Spain, 5–10 December 2016.
83. Website: GitHub. Available online: https://github.com/tensorflow/models/blob/master/research/object_detection/g3doc/tf1_detection_zoo.md (accessed on 30 August 2022).
84. Yang, C.; Xie, L.; Qiao, S.; Yuille, A.L. Training Deep Neural Networks in Generations: A More Tolerant Teacher Educates Better Students. *Proc. AAAI Conf. Artif. Intell.* 2019, 33, 5628–5635. [CrossRef]
85. Rawat, W.; Wang, Z. Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Comput.* 2017, 29, 2352–2449. [CrossRef]
86. Tian, Y.; Gelernter, J.; Wang, X.; Chen, W.; Gao, J.; Zhang, Y.; Li, X. Lane Marking Detection via Deep Convolutional Neural Network. *Neurocomputing* 2018, 280, 46–55. [CrossRef]
87. Mahmoud, Y.; Xiao, W.; Zeineldin, H.H. A Simple Approach to Modeling and Simulation of Photovoltaic Modules. *IEEE Trans. Sustain. Energy* 2012, 3, 185–186. [CrossRef]

88. Rauschenbach, H.S. Solar Cell Array Design Handbook: The Principles and Technology of Photovoltaic Energy Conversion; Springer Science & Business Media: Berlin/Heidelberg, Germany, 2012.
89. Kumari, J.S.; Babu, C. Mathematical Modeling and Simulation of Photovoltaic Cell Using Matlab-Simulink Environment. *Int. J. Electr. Comput. Eng. IJECE* 2011, 2, 26–34. [CrossRef]