

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ВЕТЕРИНАРНОЇ
МЕДИЦИНИ ТА БІОТЕХНОЛОГІЙ ІМ. С.З. ГЖИЦЬКОГО
ФАКУЛЬТЕТ МЕХАНІКИ, ЕНЕРГЕТИКИ ТА ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ
КАФЕДРА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ**

КВАЛІФІКАЦІЙНА РОБОТА

другого (магістерського) рівня вищої освіти

на тему: **«Моніторинг стану фотоелектричних установок з
використанням згорткової нейронної мережі»**

Виконав: студент групи Іт-61

Спеціальності 126 «Інформаційні системи та
технології»

(шифр і назва)

Павлюк Роман Степанович

(Прізвище та ініціали)

Керівник: к.т.н., доцент Татомир А.В.
(Прізвище та ініціали)

Рецензент: к.т.н., доцент Сиротюк С.В.
(Прізвище та ініціали)

ДУБЛЯНИ-2025

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ПРИРОДОКОРИСТУВАННЯ
ФАКУЛЬТЕТ МЕХАНІКИ, ЕНЕРГЕТИКИ ТА ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ
КАФЕДРА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ

Другий (магістерський) рівень вищої освіти
Спеціальність 126 «Інформаційні системи та технології»

«ЗАТВЕРДЖУЮ»

Завідувач кафедри _____

д.т.н., проф. А.М. Тригуба

«_____» _____ 2025 р.

ЗАВДАННЯ

на кваліфікаційну роботу студенту

Павлюку Роману Степановичу

1. Тема роботи: «Моніторинг стану фотоелектричних установок з використанням згорткової нейронної мережі»

Керівник роботи Татомир Андрій Володимирович, професор
затверджені наказом по університету від 28.02.2025 року № 140/к-с.

2. Строк подання студентом роботи 10.12.2025 р.

3. Вихідні дані до роботи: набір даних для навчання моделі; параметри нормалізації та масштабування зображень; архітектури згорткових нейронних мереж для порівняння (EfficientNetB0, MobileNetV2, ResNet50V2); програмні засоби реалізації (Python, TensorFlow, Keras, NumPy, Pandas, Streamlit).

4. Зміст розрахунково-пояснювальної записки (перелік питань, які необхідно розробити)_____

Вступ.

Аналіз сучасних методів та технологій моніторингу стану фотоелектричних установок.

Розробка моделі моніторингу стану фотоелектричних установок на основі згорткової нейронної мережі.

Результати проєктування та створення інформаційної системи підтримки прийняття рішень моніторингу стану фотоелектричних установок.

Охорона праці та безпека у надзвичайних ситуаціях.

Економічна ефективність.

Висновки та пропозиції.

Список використаної літератури.

5. Перелік ілюстраційного матеріалу (з точним зазначенням обов'язкових слайдів): аналіз сучасних методів та технологій моніторингу стану фотоелектричних установок; розробка моделі моніторингу стану фотоелектричних установок на основі згорткової нейронної мережі; результати проєктування та створення інформаційної системи підтримки прийняття рішень моніторингу стану фотоелектричних установок; економічна ефективність.

6. Консультанти з розділів:

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
1, 2, 3, 5	<i>Татомир А.В., доц. кафедри інформаційних технологій</i>		
4	<i>Городецький І.М., доцент кафедри інженерної механіки</i>		

7. Дата видачі завдання

28 лютого 2025 р.

Календарний план

№ з/п	Назва етапів кваліфікаційної роботи	Терміни виконання етапів роботи	Примітка
1	<i>Написання першого розділу</i>	28.02-20.03.25	
2	<i>Виконання другого розділу та аркушів ілюстраційного матеріалу до нього</i>	21.03-14.06.25	
3.	<i>Виконання третього розділу та аркушів ілюстраційного матеріалу до нього</i>	15.06.25-10.07.25	
4.	<i>Написання розділу «Охорона праці та безпека у надзвичайних ситуаціях»</i>	11.07-31.08.25	
5.	<i>Оцінення ефективності запропонованої системи</i>	01.09-31.10.25	
6.	<i>Завершення оформлення розрахунково-пояснювальної записки та аркушів ілюстраційного матеріалу</i>	01-30.11.25	
7.	<i>Завершення роботи в цілому</i>	01-10.12.25	

Студент _____ Павлюк Р. С.
(підпис)

Керівник роботи _____ Татомир А.В.
(підпис)

УДК 004.93'1:621.383.51

Моніторинг стану фотоелектричних установок з використанням згорткової нейронної мережі.

Павлюк Р. С. Кафедра інформаційних технологій – Дубляни, ЛНУВМ, 2025.

Кваліфікаційна робота: 91 с. текст. част., 21 рис., 10 табл., 14 арк. ілюстраційного матеріалу, 45 джерел.

Проаналізовано сучасні методи моніторингу технічного стану фотоелектричних установок та запропоновано інтелектуальну систему підтримки прийняття рішень для автоматизованої діагностики дефектів сонячних панелей. Розглянуто тенденції розвитку фотоелектричної енергетики та проведено аналіз існуючих підходів, що ґрунтуються на термографії, візуальному огляді та дистанційному моніторингу.

Розроблено модель моніторингу на основі згорткових нейронних мереж. Проведено підготовку датасету, побудовано навчальні та тестові вибірки, здійснено експериментальне порівняння архітектур CNN (EfficientNetB0, MobileNetV2, ResNet50V2). Оцінювання ефективності виконано за метриками точності, повноти, F1-міри та часу навчання. Найкращі результати продемонструвала модель MobileNetV2. Здійснено проєктування та реалізацію інформаційної системи моніторингу. Розроблено структурну схему ІСППР, архітектуру програмного комплексу та модулі збору, зберігання й аналітичної обробки даних. Реалізовано інтеграцію результатів нейронної мережі та створено користувацький інтерфейс на базі Streamlit для візуалізації діагностичних висновків у реальному часі.

Розглянуто питання охорони праці, безпеки під час розробки програмного продукту та мінімізації ризиків під час експлуатації ІСППР. Здійснено економічну оцінку ефективності впровадження системи.

Ключові слова: фотоелектричні установки; моніторинг; згорткова нейронна мережа; машинне навчання; безпілотний літальний апарат; термографія; діагностика дефектів; інформаційна система підтримки прийняття рішень; Streamlit; відновлювана енергетика.

ЗМІСТ

ВСТУП	7
Розділ 1. АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ТЕХНОЛОГІЙ МОНІТОРИНГУ СТАНУ ФОТОЕЛЕКТРИЧНИХ УСТАНОВОК.....	10
1.1. Стан і тенденції розвитку фотоелектричної енергетики	10
1.2. Аналіз методів моніторингу технічного стану фотоелектричних панелей	13
1.3. Використання безпілотних літальних апаратів у моніторингу фотоелектричних станцій.....	18
1.4. Методи оброблення зображень і сигналів у системах діагностики фотоелектричних установок	22
Розділ 2. РОЗРОБКА МОДЕЛІ МОНІТОРИНГУ СТАНУ ФОТОЕЛЕКТРИЧНИХ УСТАНОВОК НА ОСНОВІ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ.....	28
2.1. Вибір та опис вхідних даних для навчання нейронної мережі	28
2.2. Підготовка даних і формування DataFrame для моделювання	31
2.3. Алгоритм попередньої обробки термографічних зображень.....	32
2.4. Формування навчальної та тестової вибірок	35
2.5. Вибір архітектур згорткових нейронних мереж для порівняльного аналізу	38
2.6. Проведення навчання моделей та оцінювання їхньої ефективності.....	41
2.7. Порівняльний аналіз результатів навчання за метриками точності, повноти та швидкодії	45
Розділ 3. РЕЗУЛЬТАТИ ПРОЄКТУВАННЯ ТА СТВОРЕННЯ ІНФОРМАЦІЙНОЇ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ МОНІТОРИНГУ СТАНУ ФОТОЕЛЕКТРИЧНИХ УСТАНОВОК.....	49
3.1. Загальна структура інформаційної системи моніторингу	49
3.2. Архітектура програмного комплексу ІСППР	52
3.3. Модулі збору, зберігання та аналітичної обробки даних	57
3.4. Інтеграція результатів згорткової нейронної мережі в систему моніторингу	60
3.5. Інтерфейс користувача та візуалізація результатів діагностики	62

Розділ 4. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА У НАДЗВИЧАЙНИХ СИТУАЦІЯХ.....	67
4.1. Аналіз умов праці під час розробки ІСППР	67
4.2. Аналіз небезпечних і шкідливих виробничих чинників.....	68
4.3. Безпека праці під час використання ІСППР	70
4.4. Захист населення під час надзвичайних ситуацій	72
Розділ 5. ЕКОНОМІЧНА ЕФЕКТИВНІСТЬ ВІД ВИКОРИСТАННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ МОНІТОРИНГ СТАНУ ФОТОЕЛЕКТРИЧНИХ УСТАНОВОК	73
ВИСНОВКИ І ПРОПОЗИЦІЇ.....	77
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	81
ДОДАТКИ	86
Додаток А. Фрагмент коду ІСППР для моніторингу фотоелектричних установок	87

ВСТУП

Швидке зростання масштабів і складності фотоелектричних сонячних електростанцій потребує впровадження передових методів контролю їхнього технічного стану. У сучасних умовах саме системи моніторингу відіграють вирішальну роль у забезпеченні надійності, ефективності та безпечної експлуатації енергетичних об'єктів. Класичні методи перевірки – ручний огляд або періодичне вимірювання електричних параметрів – уже не задовольняють вимог щодо швидкості, об'єктивності та точності. Тому актуальним напрямом є створення інтелектуальних систем моніторингу, що здатні автоматично збирати, аналізувати та інтерпретувати великі обсяги даних, зокрема за допомогою технологій глибинного навчання [18; 19].

Одним із найбільш перспективних підходів до діагностики стану фотоелектричних панелей є використання згорткових нейронних мереж (CNN), які довели свою ефективність у задачах комп'ютерного зору та класифікації зображень. Такі моделі можуть автоматично виявляти дефекти модулів, гарячі точки, забруднення або тріщини, використовуючи оптичні та інфрачервоні зображення [38]. Поєднання CNN-аналізу з термографічними даними, отриманими за допомогою безпілотних літальних апаратів, дає змогу оперативно проводити обстеження великих фотоелектричних полів. Завдяки автоматизованій обробці даних можливо не лише визначити факт наявності несправності, але й локалізувати її положення на поверхні панелі, що значно підвищує ефективність технічного обслуговування [34].

Важливою особливістю сучасних систем моніторингу є інтеграція термографічних і телеметричних даних у єдине інформаційне середовище. Такий підхід дозволяє проводити аналіз у режимі реального часу та забезпечувати багаторівневу оцінку стану фотоелектричних установок. У запропонованій методології передбачається використання двох згорткових нейронних мереж на основі регіонів, які об'єднуються у спільну структуру для підвищення точності виявлення аномалій. Система здійснює збір даних за допомогою дронів, їх

оброблення, формування теплових карт та класифікацію дефектів, після чого автоматично генерує звіти для подальшого аналізу.

Об'єктом дослідження є фотоелектрична установка – комплекс технічних пристроїв, що забезпечує перетворення сонячного випромінювання в електричну енергію та включає сонячні панелі, інвертор, систему збору даних і комунікаційне обладнання.

Предметом дослідження є процес моніторингу стану фотоелектричних установок із використанням згорткових нейронних мереж, який охоплює етапи збору термографічних і телеметричних даних, їх попередню обробку, навчання моделі, виявлення та класифікацію дефектів, а також оцінку ефективності системи за статистичними показниками точності.

Засобами дослідження є апаратно-програмний комплекс, що поєднує безпілотний літальний апарат із термографічною камерою для збору даних, комп'ютер із програмним забезпеченням для обробки та аналізу інформації, а також алгоритми глибинного навчання, реалізовані в середовищах Python, TensorFlow або PyTorch. Додатково використовуються бібліотеки OpenCV для обробки зображень, NumPy і Pandas для аналізу даних, а також засоби візуалізації результатів.

Метою кваліфікаційної роботи є розроблення інтелектуальної системи моніторингу стану фотоелектричних установок на основі згорткової нейронної мережі, що забезпечує автоматичне виявлення дефектів і підвищує надійність експлуатації сонячних електростанцій. Для досягнення цієї мети передбачено аналіз сучасних підходів до контролю фотоелектричних систем, створення набору даних термографічних зображень, побудову архітектури CNN-моделі, проведення навчання та тестування на реальних даних, а також оцінювання точності та стабільності результатів.

Практичне значення роботи полягає у створенні прототипу системи моніторингу, здатної виявляти гарячі точки та локалізувати дефекти фотоелектричних панелей у реальному часі. Впровадження таких технологій забезпечує зниження експлуатаційних витрат, підвищення ефективності

виробництва електроенергії та подовження терміну служби обладнання. Теоретичне значення дослідження полягає у розвитку методів застосування згорткових нейронних мереж у сфері відновлюваної енергетики, зокрема у задачах аналізу багатовимірних термографічних даних.

Розділ 1.

АНАЛІЗ СУЧАСНИХ МЕТОДІВ ТА ТЕХНОЛОГІЙ МОНІТОРИНГУ СТАНУ ФОТОЕЛЕКТРИЧНИХ УСТАНОВОК

1.1. Стан і тенденції розвитку фотоелектричної енергетики

Упродовж останніх років сектор сонячної фотоелектричної (PV) енергетики демонструє значне розширення, що є одним із ключових трендів у переході до відновлюваних джерел енергії. Згідно з даними International Energy Agency (IEA), щорічні додаткові потужності у відновлюваній енергетиці в 2023 році збільшились майже на 50 % й досягли приблизно 510 ГВт – найшвидший темп росту за останні два десятиліття [24].




Рисунок 1.1 – Глобальна динаміка встановлених потужностей сонячної енергетики у 2015–2023 роках [24]

Зокрема, установки сонячної фотоелектрики склали значну частину цього приросту, а згідно з даними SolarPower Europe, приріст у 2023 році становив приблизно 447 ГВт – що відповідає зростанню на 87 % порівняно з попереднім

роком [41]. Ці статистичні дані свідчать про зростаючу роль PV-технологій у глобальному енергетичному балансі, причому зростання стимулюється як зниженням вартості обладнання, так і державними програмами підтримки.



Рисунок 1.2 – Прогноз глобальних річних інсталяцій фотоелектричних систем за регіонами до 2032 року [41]

Економічний масштаб цієї галузі також помітний: згідно з аналізом індустрії, ринок сонячної енергії у 2023 році оцінювався приблизно у US\$ 253,7 млрд і прогнозується досягнення US\$ 436,4 млрд до 2032 року при середньорічному темпі зростання (CAGR) близько 6 % [23]. Це означає, що інвестиції у фотоелектричні системи стають не лише екологічно обґрунтованими, але й економічно привабливими, що підсилює їхнє впровадження у масштабі промислових та комерційних об'єктів.

Що стосується типів фотоелектричних систем, то сучасний ринок характеризується переважанням декількох технологій сонячних панелей. За оглядом [26] монокристалічні кремнієві модулі залишаються домінуючими за часткою ринку завдяки своїй високій ефективності та надійності, тоді як полікристалічні та тонкоплівкові рішення здобувають застосування там, де важлива нижча вартість або гнучкість конструкції. Інформація із практичного огляду підтверджує, що монокристалічні панелі зазвичай мають ефективність у межах 20-22 % (у деяких випадках до 23-24 %) порівняно з полікристалічними з

показниками 15-17 % або трохи вище [22]. Окрім цього, зміни в масштабах встановлення також впливають на вибір технології: великі промислові фотоелектричні станції часто застосовують технології з високою ефективністю та оптимізацією виробництва на Вт, тоді як менші системи і дахові рішення більше орієнтовані на баланс між вартістю та продуктивністю.

Для графічного уявлення ключових показників росту ринку фотоелектрики наводжу приблизний рисунок динаміки (за даними 2022–2024 років):




Рисунок 1.3 – Річні встановлення PV (за регіонами/групами країн) [24]

Цей рисунок ілюструє не лише зростання абсолютної встановленої потужності сонячної енергетики, але й те, як технологічна структура (типи панелей) змінюється з часом.

У контексті України та регіону Східної Європи також спостерігається подібна тенденція – хоча темпи впровадження дещо нижчі за глобальні через інфраструктурні, фінансові чи регуляторні бар'єри. Однак потенціал для зростання залишається значним, особливо з огляду на державні цілі щодо підвищення частки ВДЕ у загальному енергобалансі.

Підсумовуючи, можна зробити висновок, що фотоелектрична енергетика перебуває на стадії активного зростання з чіткою тенденцією до масштабування і технологічного удосконалення. Це створює сприятливі умови для розвитку систем моніторингу і діагностики – оскільки більш масштабні установки потребують більших ресурсів контролю та оптимізації. Саме тому подальший акцент дослідження переноситься на аналіз методів моніторингу технічного стану панелей, що й виконано в наступному підпункті.

1.2. Аналіз методів моніторингу технічного стану фотоелектричних панелей

Контроль за технічним станом фотоелектричних (ПВ) панелей є складним і багаторівневим завданням, яке вимагає застосування різних методик – електричних вимірювань, візуального та термографічного контролю, а також дистанційного моніторингу із застосуванням IoT-платформ. У цьому підрозділі проаналізовано основні підходи до моніторингу, наведено їх переваги і недоліки, а також розглянуто математичні моделі та приклади візуалізації.

Електричні та електрофізичні методи

Найбільш традиційним методом контролю ПВ-установок є аналіз I-V (струм-напруга) характеристики панелі чи стрічки панелей. Зі зміною температури T та освітленості G точка максимальної потужності змінюється, що можна виразити як:

$$P_{max} = V_{mpp} \cdot I_{mpp}, \quad (1.1)$$

де V_{mpp} – відповідно напруга і струм у точці максимальної потужності.

Відомо також, що коефіцієнт заповнення (fill factor, FF) виражається як:

$$FF = \frac{P_{max}}{V_{oc} \cdot I_{sc}}, \quad (1.2)$$

де V_{oc} – напруга холостого ходу; I_{sc} – струм короткого замикання.

Зниження показників V_{mpp} або FF може свідчити про деградацію модуля, підвищення послідовного опору, затінення чи інші дефекти [18].

Перевагою аналізу I-V є можливість виявити електричні зміни без прямого огляду панелі. Однак цей метод має обмеження: він не дає безпосередньої інформації про фізичні дефекти (тріщини, delamination, гарячі точки), часом потребує зняття умов експлуатації чи спеціального обладнання, а також дає агреговані дані (для стрічки чи масиву) й може не виявляти локальні дефекти [18].

Візуальне, термографічне та інфрачервоне сканування

Другим за значимістю групою методів є візуальний та термографічний контроль панелей. Це дозволяє виявляти такі дефекти, як тріщини у комірках, delamination, гарячі точки, забруднення чи затінення.




Рисунок 1.4 – Приклад інфрачервоного зображення фотоелектричного модуля з гарячою точкою [27]

Наприклад, при термографічному скануванні панелі можуть бути видимі ділянки з підвищеною температурою (гарячі точки), які вказують на внутрішній дефект або затінення. Такі методи висвітлюють причинно-наслідкові механізми деградації панелей [25].

Формалізувати виявлення гарячої точки можна як:

$$\Delta T = T_{\text{defect}} - T_{\text{healthy}}, \quad (1.3)$$

де T_{defect} – температурна пікова точка дефекту; $T_{healthy}$ – середня температура здорової поверхні панелі.

Якщо ΔT перевищує визначений поріг (наприклад, 10 °C), панель класифікується як проблемна. Цей підхід дає візуальну локалізацію дефекту і дозволяє втрутитись до того, як дефект спричинить значну втрату продуктивності.

Однак такі методи вимагають спеціального обладнання (інфрачервоні камери), можуть бути чутливі до умов оточення (освітлення, вітер, кут огляду), та потребують подальшої автоматичної обробки зображень для великомасштабного застосування [25].

Дистанційний і IoT-моніторинг, аналітика даних

Сучасний тренд моніторингу ПВ-установок – це інтеграція датчиків, телеметрії, IoT-пристроїв та програмних платформ, які в реальному часі збирають дані про струм, напругу, температуру модулів, освітленість, швидкість вітру тощо.

Система моніторингу агрегує ці дані, порівнює з моделями очікуваної продуктивності (наприклад, на основі моделі SAM), обчислює ключові показники – наприклад, коефіцієнт продуктивності (Performance Ratio)

$$PR = \frac{E_{actual}}{G_{POA} \cdot \eta_{module} \cdot A}, \quad (1.4)$$

де E_{actual} – фактична вироблена енергія; G_{POA} – інцидентна радіація на панельну площу; η_{module} – номінальна ефективність модуля, A – площа модулів.

Якщо PR знижується нижче встановленого порогу (наприклад, 0.80), система видає сигнал тривоги [45].



Рисунок 1.5 – Електролюмінесцентна діагностика сонячних комірок з мікротріщинами [39]

Такі платформи дозволяють оперативно реагувати на відхилення, здійснювати прогнозу діагностику та зменшувати час простою. Основним недоліком є потреба в мережевій інфраструктурі, великому обсязі даних, а також правдивому моделюванню очікуваного виробітку, особливо коли система піддається впливу затінення чи часткової деградації [45].

Таблиця 1.1 – Порівняльна таблиця методів моніторингу технічного стану фотоелектричних панелей

Метод	Що контролюється	Переваги	Недоліки
I-V аналіз	Електричні параметри	виявляє електричні дефекти, відносно недорогий	не дає локалізацію дефекту, потребує спеціального обладнання
Термографія/візуальний	Гарячі точки, тріщини, delamination	локалізує проблемні ділянки, швидкий огляд великих площ	досить дорогий, чутливий до зовнішніх умов
ІоТ-/дистанційний моніторинг	Дані в реальному часі, PR, радіація	дозволяє постійно стежити, попереджати несправності	велика кількість даних, потребує інфраструктури та моделі

Схема загальної роботи системи моніторингу показано на рис. 1.6.




Рисунок 1.6 – Структура ІоТ-системи моніторингу фотоелектричних установок [21]

У цій схемі (рис. 1.6) показано основні етапи: збір даних (датчики, камери, дроном), обробка (фільтрація, нормалізація), аналіз (алгоритми, моделі), інтерпретація результатів та заходи з технічного обслуговування.

На практиці найефективнішими є комбіновані підходи: наприклад, термографія + I-V аналіз або IoT-моніторинг + алгоритми обробки зображень для автоматичної класифікації дефектів. Такий підхід дозволяє підвищити точність діагностики, локалізувати дефекти й зменшити витрати на обслуговування.

Отже, аналізуючи сучасні методи моніторингу, стає очевидним, що вибір методу чи їх поєднання має залежати від масштабу установки, типу панелей, бюджетних обмежень та бажаної швидкості реагування.

1.3. Використання безпілотних літальних апаратів у моніторингу фотоелектричних станцій

Стрімке зростання масштабів фотоелектричних станцій у світі зумовлює потребу у створенні ефективних систем моніторингу, здатних охоплювати великі площі при мінімальних витратах часу. Одним із найбільш перспективних напрямів розвитку є використання безпілотних літальних апаратів (БПЛА) з інтегрованими тепловізійними, RGB та мультиспектральними камерами, які дозволяють здійснювати високоточну діагностику стану панелей у режимі реального часу [1].

Завдяки використанню сучасних дронів типу *DJI Mavic 3 Thermal* або *Autel Evo II Dual*, які мають роздільну здатність до 640×512 пікселів у тепловому діапазоні, можна виявляти гарячі точки розміром менше 5 см навіть на висоті 40м.

Тепловізійний аналіз фотоелектричних модулів

Основним завданням аеромоніторингу є виявлення термічних аномалій, які вказують на потенційні несправності в елементах панелей.

Температурне поле панелі можна описати як функцію:

$$T(x,y) = T_{amb} + \Delta T(x,y), \quad (1.5)$$

де T_{amb} – температура навколишнього середовища; $\Delta T(x,y)$ – локальне перевищення температури.

Якщо температура окремої ділянки панелі перевищує середнє значення по поверхні більше ніж на 10°C , така зона класифікується як *hot spot*:

$$\Delta T_{crit} = T_{max} - T_{avg} > 10. \quad (1.6)$$

Відповідно, теплова карта, отримана з дрона, подається у вигляді матриці T_{ij} , яку можна автоматично обробляти за допомогою згорткової нейронної мережі CNN для класифікації типів дефектів (перегрів, тріщини, деламінування) [28].




Рисунок 1.7 – Конвеєр для виявлення фотоелектричних модулів за тепловими зображеннями: (а) зображення з порогом; (б) матриця відстаней; (с) бінаризоване зображення; (d) сегментація та вилучення лінії регресії; (е) кластеризація та оцінка середньої лінії фотоелектричних модулів [28]

На рисунку 1.7 видно ділянки підвищеної температури (жовто-червоні області), які свідчать про наявність дефектів комірок або забруднень поверхні модуля.

Інтеграція RGB- та ІЧ-зображень

Поєднання теплових і візуальних даних дозволяє суттєво підвищити точність діагностики. Для кожної панелі формується вектор ознак:

$$F = [T_{max}, T_{mean}, \sigma_T, I_{mean}, S_{edge}, H_{texture}]. \quad (1.7)$$

де T_{max} – максимальна температура пікселя; σ_T – стандартне відхилення температурного поля; I_{mean} – середня інтенсивність зображення, S_{edge} – ступінь контурності (edge sharpness); $H_{texture}$ – ентропія текстури поверхні.

Ці ознаки використовуються CNN-моделлю для класифікації типу пошкодження за навченою базою термо- та візуальних зображень.

Дослідження показують, що інтегрований підхід забезпечує підвищення точності класифікації дефектів на 8-12% порівняно з аналізом лише термографічних даних [3].




Рисунок 1.8 – Кількість зображень для кожного класу несправностей фотоелектричних систем. Набір даних InfraredSolarModule (ISM), геометричне перетворення (GT), WGAN, DDPM [38]

Планування маршрутів польоту дрона

Для оптимального покриття території застосовуються алгоритми планування траєкторій на основі принципу мінімізації довжини маршруту при забезпеченні повного перекриття поля спостереження:

$$\min L = \sum_{i=1}^{n-1} d(p_i, p_{i+1}). \quad (1.8)$$

за умови

$$\bigcup_{i=1}^n A(p_i, r_i) \supseteq S, i=1. \quad (1.9)$$

де p_i – точки зйомки; $A(p_i, r_i)$ – зона огляду камери з радіусом r_i ; S – площа фотоелектричної станції.

Залежно від геометрії об'єкта, використовуються стратегії «змійки» (lawn-mower pattern) або алгоритми *coverage path planning*, які реалізуються у програмах Pix4D Mapper, DroneDeploy чи у власних Python-скриптах із бібліотеками *Shapely* та *NetworkX*.



Рисунок 1.9 – Схема сітки, зображення: розгортання дрона [33]

Порівняльна характеристика методів моніторингу фотоелектричних панелей подана у табл. 1.2.

Застосування безпілотних літальних апаратів значно підвищує ефективність і точність діагностики стану фотоелектричних установок. Аеромоніторинг дозволяє швидко охоплювати великі площі, мінімізувати ручну працю та проводити моніторинг навіть у важкодоступних місцях.

**Таблиця 1.2 – Порівняльна ефективність різних методів моніторингу
фотоелектричних панелей**

№	Метод контролю	Тип сенсора	Охоплення території, га/год	Просторова роздільна здатність, см/пікс	Точність виявлення дефектів, %
1	Наземна термографія	FLIR T540	0.2	0.2	88
2	Аеромоніторинг (ІЧ)	DJI Mavic 3 Thermal	40–50	5	93
3	Комбінована RGB+ІЧ UAV-система	Autel Evo II Dual 640T	30–40	3	96–98

Комбінація RGB-та ІЧ-зйомки у поєднанні зі згортковими нейронними мережами забезпечує найвищу точність класифікації дефектів, тоді як використання оптимізованих маршрутів польоту дозволяє зменшити витрати енергії дрона і скоротити час обстеження.

Отримані дані формують основу для подальшого створення інтелектуальної системи моніторингу, де інформація, зібрана з БПЛА, автоматично обробляється та аналізується моделями глибинного навчання.

1.4. Методи оброблення зображень і сигналів у системах діагностики фотоелектричних установок

Сучасні системи моніторингу технічного стану фотоелектричних (ФЕ) установок ґрунтуються на аналізі великого обсягу даних – теплових, візуальних, електричних і спектральних сигналів. Їх оброблення потребує застосування спеціалізованих алгоритмів, здатних автоматично виділяти ознаки дефектів і здійснювати їх класифікацію. Найбільш ефективними напрямками є оброблення зображень методами цифрової фільтрації, трансформацій Фур'є, статистичних дескрипторів та глибинного навчання [1, 2].

Попередня обробка зображень

На першому етапі виконується фільтрація шумів і нормалізація яскравості. Для термографічних зображень $I(x, y)$ застосовується гаусове згладжування:

$$I'(x, y) = \sum_{i=-k}^k \sum_{j=-k}^k G(i, j) \cdot I(x - i, y - j). \quad (1.10)$$

де $G(i, j)$ – двовимірний гаусовий функція з дисперсією σ .

$$G(i, j) = \frac{1}{2\pi \sigma^2} \exp\left(-\frac{i^2 + j^2}{2\sigma^2}\right). \quad (1.11)$$

Це дозволяє усунути випадкові теплові коливання, спричинені вітром або зміною освітлення, і покращити контрастність гарячих точок.

Для підвищення різкості та виявлення тріщин використовується оператор Собеля:

$$\nabla I = \sqrt{(G_x \cdot I)^2 + (G_y \cdot I)^2}. \quad (1.12)$$

де G_x – ядра горизонтальної та вертикальної похідної. Результат застосовується як карта контурів при виявленні деламінування або механічних пошкоджень панелей [3].




Рисунок 1.10 – Етапи попередньої обробки термографічного зображення фотоелектричної панелі [36]

Спектральні та вейвлет-перетворення

Після фільтрації виконується спектральний аналіз, що дозволяє відокремити частотні компоненти сигналу. Для двовимірного зображення використовується перетворення Фур'є:

$$F(u,v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I(x,y) e^{-j2\pi(ux/M + vy/N)}. \quad (1.13)$$

Високочастотні компоненти вказують на локальні дефекти, тоді як низькочастотні відображають загальну текстуру поверхні.

У практичних системах діагностики дедалі частіше використовується вейвлет-перетворення, яке забезпечує одночасний часово-просторовий аналіз:

$$W(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} I(t) \psi^*\left(\frac{t-b}{a}\right) dt. \quad (1.14)$$

де ψ – материнська вейвлет-функція (часто використовується “Mexican Hat”). Такий підхід дозволяє ідентифікувати дрібні пошкодження в межах окремих комірок без втрати контексту всієї панелі [4].

Згорткові нейронні мережі для класифікації дефектів

Для автоматичної ідентифікації несправностей найчастіше застосовують згорткові нейронні мережі (Convolutional Neural Networks, CNN). Їх принцип полягає у формуванні набору карт ознак, де кожен згортковий шар виділяє певний тип інформації – від країв і контурів до складних термічних патернів [5].

Згортковий шар обчислює:

$$S_{ij}^{(l)} = f\left(\sum_{m,n} w_{mn}^{(l)} \cdot x_{(i+m)(j+n)}^{(l-1)} + b^{(l)}\right). \quad (1.15)$$

де $S_{ij}^{(l)}$ – вихідна активація, $w_{mn}^{(l)}$ – ядро згортки; $b^{(l)}$ – зміщення, $f(\cdot)$ – нелінійна функція (ReLU).

Для скорочення розмірності використовується підвибірка (max pooling):

$$P_{ij}^{(l)} = \max_{(m,n) \in R} S_{i+m,j+n}^{(l)}. \quad (1.16)$$

Кінцевий шар Softmax виконує класифікацію дефектів (наприклад, *гаряча точка, тріщина, деламінування, затінення*).

Точність таких систем, навчених на відкритих наборах даних (наприклад, PVNet або SolarDefectDB), досягає 97–99 % [38].




Рисунок 1.11 – Архітектура згорткової нейронної мережі для діагностики дефектів фотоелектричних панелей [38].

Таблиця 1.3 – Порівняння ефективності методів оброблення даних у системах діагностики ФЕ панелей

№	Метод	Тип вхідних даних	Основне призначення	Середня точність, %
1	Гаусове згладжування + Собеля	Термозображення	Виявлення країв, шумозменшення	90–92
2	Вейвлет-перетворення	Теплові сигнали	Ідентифікація локальних дефектів	93–95
3	CNN + Softmax	Зображення RGB/ІЧ	Класифікація типу дефекту	97–99
4	Кореляційний аналіз	Тепло + електричні дані	Виявлення деградації	94

Методи оброблення зображень і сигналів стали фундаментом сучасних систем діагностики фотоелектричних установок. Поєднання традиційних цифрових алгоритмів фільтрації із нейронними мережами дозволяє не лише виявляти, а й прогнозувати розвиток дефектів у реальному часі. Застосування CNN-архітектур, таких як *ResNet50*, *EfficientNet* або *YOLOv8*, забезпечує гнучкість моделі та здатність працювати із зображеннями різної якості. Синергія даних термографії, електричних параметрів та аналітики IoT-платформ формує

основу інтелектуальної системи моніторингу, що забезпечує підвищення енергоефективності, надійності та довговічності фотоелектричних станцій.

1.5. Завдання кваліфікаційної роботи

Зі зростанням масштабів фотоелектричних сонячних електростанцій постає потреба у створенні надійних, гнучких і високоточних систем моніторингу, здатних оперативно виявляти несправності в роботі панелей. Традиційні методи контролю, що базуються на періодичному візуальному огляді або вибірових електричних вимірюваннях, не забезпечують достатньої ефективності при обслуговуванні великих енергетичних об'єктів. Тому актуальним стає використання інтелектуальних систем, які поєднують аналіз теплових і візуальних даних з можливостями штучного інтелекту та безпілотних технологій.

Метою кваліфікаційної роботи є розроблення інтелектуальної системи моніторингу стану фотоелектричних установок на основі згорткової нейронної мережі, що забезпечує автоматичне виявлення дефектів і підвищує надійність експлуатації сонячних електростанцій.

Для досягнення поставленої мети в роботі передбачено вирішення таких завдань:

1. Здійснити огляд сучасного стану проблеми моніторингу фотоелектричних систем, проаналізувати основні підходи до діагностики та оцінити їх ефективність щодо своєчасного виявлення дефектів.
2. Дослідження можливостей використання безпілотних літальних апаратів для дистанційного моніторингу фотоелектричних панелей.
3. Розроблення методу попередньої обробки зображень, отриманих під час аеромоніторингу, з метою зменшення шумів, підвищення контрастності та точності розпізнавання.

4. Побудова архітектури нейронної мережі для класифікації типів дефектів панелей.

5. Інтеграція результатів аналізу термографічних даних із супровідними параметрами роботи панелей, такими як струм, напруга та температура навколишнього середовища, для створення комплексної системи оцінювання стану фотоелектричної установки.

Реалізація поставлених завдань забезпечить досягнення мети дослідження – створення автоматизованої системи моніторингу, яка дозволяє підвищити надійність і довговічність фотоелектричних установок, зменшити експлуатаційні витрати та сприяти сталому розвитку відновлюваної енергетики.

РОЗДІЛ 2.

РОЗРОБКА МОДЕЛІ МОНІТОРИНГУ СТАНУ ФОТОЕЛЕКТРИЧНИХ УСТАНОВОК НА ОСНОВІ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ

2.1. Вибір та опис вхідних даних для навчання нейронної мережі

Для побудови моделі моніторингу технічного стану фотоелектричних установок у роботі використано відкритий датасет Solar Panel Infrared Images, опублікований на платформі Roboflow Universe [40]. Цей набір даних містить тепловізійні знімки сонячних панелей, отримані під час інспекцій з використанням безпілотних літальних апаратів. Особливістю датасету є те, що зображення відображають різні типи дефектів: локальні гарячі точки, нерівномірне нагрівання елементів, перегріті комірки та дефектні секції модулів. Такий матеріал добре підходить для навчання згорткових нейронних мереж, оскільки дозволяє моделі виявляти просторові патерни, пов'язані з температурними аномаліями [37].

У вихідному наборі даних представлені 2 класи:

0 – справна панель,

1 – дефектна панель.

Після первинного опрацювання було сформовано підсумковий набір даних, основні характеристики якого наведено у таблиці 2.1.

Таблиця 2.1 – Характеристики використаного датасету

Параметр	Значення
Загальна кількість зображень	1832
Кількість справних панелей (клас 0)	1120
Кількість дефектних панелей (клас 1)	712
Формат зображень	JPEG/PNG
Середня роздільність	320×320 px
Тип зображень	Термографічні (IR)
Джерело даних	Roboflow Universe




Рисунок 2.1 – Зображення справних та дефектних панелей

Для кращого розуміння розподілу даних було побудовано гістограму кількості зразків у кожному класі (рис. 2.2). Така візуалізація дозволяє оцінити баланс вибірки, що важливо для подальшого навчання моделі, оскільки дисбаланс може спричинити зміщення прогнозів нейронної мережі у бік більш представленого класу [31].




Рисунок 2.2 – Розподіл класів у датасеті (справні та дефектні панелі)

Термографічні зображення несуть інформацію про температуру елементів фотоелектричної панелі. Нехай функція $T(x, y)$ позначає температуру пікселя з координатами (x, y) .

Дефект, зокрема гаряча точка, виникає тоді, коли температура певної ділянки значно відхиляється від середнього значення по зображенню. Це можна описати формулою:

$$D(x, y) = \begin{cases} 1, & \text{якщо } T(x, y) - \bar{T} \geq \Delta T, \\ 0, & \text{інакше,} \end{cases} \quad (2.1)$$

де $\bar{T}$ – середнє значення температури по всій панелі; ΔT – порогова різниця температур (зазвичай 10–15 °C, залежно від стандартів інспекції [32]).

Саме такі відмінності у температурних патернах і є ключовими ознаками, що виявляються згортковою нейронною мережею. Поверхні з високою щільністю «теплих» пікселів формують характерні контури, які CNN здатна розпізнати завдяки фільтрувальним ядрам.

Вибір термографічних зображень як основних вхідних даних обумовлений такими факторами:

- Тепловізійні зображення чітко демонструють приховані дефекти, які не можна побачити у видимому спектрі.
- Безпілотні апарати забезпечують охоплення великих площ, що робить дані репрезентативними для промислових СЕС.
- Анотація з класами дозволяє застосувати контрольоване навчання, що забезпечує високу точність CNN.
- Наявність подібних наборів у літературі підтверджує їх ефективність для діагностики PV-модулів [37; 32].

Таким чином, обраний датасет повністю відповідає задачам кваліфікаційної роботи та дає можливість сформувати якісну тренувальну вибірку для побудови моделі моніторингу стану фотоелектричних установок.

2.2. Підготовка даних і формування DataFrame для моделювання

Після визначення джерела вхідних даних наступним кроком стало формування структурованої вибірки, яка забезпечує зручність подальшого опрацювання зображень та їх інтеграцію у процес навчання згорткової нейронної мережі. Оскільки вихідні матеріали представлені у вигляді термографічних знімків, було важливо не лише уніфікувати їхній розмір і формат, а й доповнити їх супровідною інформацією, що описує технічний стан панелей. З цією метою всі зразки були організовані у вигляді єдиної табличної структури DataFrame, де для кожного зображення зберігався індекс, оцінена ймовірність дефекту, цільова мітка класу та тип фотоелектричного модуля. Подібний підхід широко застосовується в сучасних дослідженнях з комп'ютерного зору, оскільки дозволяє поєднати візуальні та аналітичні дані у єдиному форматі [40].

Для кожного зображення x_i у вибірці формувалася набір атрибутів:

$$d_i = (i, p_i, y_i, t_i) , \quad (2.2)$$

де i – порядковий номер зразка; p_i – ймовірність дефектності у діапазоні від 0 до 1; y_i – істинна мітка класу, що приймає значення 0 для справної панелі й 1 для дефектної; t_i – описує тип модуля (mono або poly).

Сукупність таких записів формує структуровану множину:

$$DF = \{d_1, d_2, \dots, d_n\} . \quad (2.3)$$

Ця множина (2.3) використовується на всіх подальших етапах обробки та навчання моделі. Приклад перших п'яти записів наведено у таблиці 2.2.

Таблиця 2.2 – Фрагмент сформованого DataFrame

index	defect_proba	label	type
0	1.0	1	mono
1	1.0	1	mono
2	1.0	1	mono
3	0.0	0	mono
4	1.0	1	mono

У процесі формування DataFrame було перевірено відсутність пошкоджених або порожніх файлів, а також відповідність між кількістю зображень та обсягом міток. Важливою частиною підготовки даних стала нормалізація значень пікселів, що є стандартною процедурою у задачах класифікації зображень. Значення інтенсивності спочатку зчитуються у діапазоні $[0,255]$, а потім перетворюються до нормованого вигляду за формулою:

$$x'_i = \frac{x_i}{255} . \quad (2.4)$$

Це дозволяє уникнути надмірних градієнтів під час навчання та підвищує стабільність оптимізації згорткової мережі [37].

Для оцінювання балансу вибірки було побудовано гістограму розподілу класів, що дає змогу оцінити пропорцію між справними та дефектними панелями.

Організація даних у формі DataFrame має суттєві переваги. Такий формат забезпечує можливість швидкої фільтрації, об'єднання та візуального аналізу інформації, що дозволяє оперативно відстежувати характеристики зразків та їх зв'язок із цільовими мітками. Крім того, DataFrame легко інтегрується з бібліотеками TensorFlow та PyTorch, оскільки може бути перетворений у формат `tf.data.Dataset`, що значно прискорює процес батчування та подальшого навчання моделі [4]. Відтак, створення структурованого DataFrame є основним кроком, який визначає якість усіх наступних етапів моделювання та проєктування системи моніторингу фотоелектричних установок.

2.3. Алгоритм попередньої обробки термографічних зображень

Попередня обробка термографічних зображень є ключовим етапом у підготовці даних для моделювання, оскільки саме на цьому етапі формується якість вхідної інформації, що надходить до згорткової нейронної мережі. Враховуючи те, що інфрачервоні зображення фотоелектричних панелей містять

теплові аномалії різної інтенсивності та можуть відрізнятися за розміром, контрастом та рівнем шуму, алгоритм їх опрацювання має бути достатньо гнучким і водночас стабільним. Подібні підходи описані у сучасних роботах з діагностики PV-модулів за допомогою тепловізійних камер [40; 37; 31].

Першим кроком стало коректне зчитування зображень у форматі масиву пікселів. Оскільки початкові дані надходять у відтинках сірого, кожне зображення представляється у вигляді матриці:

$$I(x,y), \quad x \in [1,W], y \in [1,H] . \quad (2.5)$$

де W та H – ширина та висота зображення відповідно.

Інтенсивність пікселя відображає температуру відповідної ділянки фотоелектричної поверхні.

Наступним етапом стала нормалізація інтенсивностей. Для забезпечення стабільної роботи мережі значення пікселів перетворювалися за формулою:

$$I'(x,y) = \frac{I(x,y)}{255} . \quad (2.6)$$

Це дозволило привести дані до спільного діапазону $[0,1]$ і тим самим уникнути різких перепадів у градієнтах під час оптимізації. Дослідження показують, що така форма нормалізації пришвидшує збіжність CNN і зменшує ризик переобучення [32].

Для забезпечення сумісності з архітектурами згорткових моделей зображення було перетворено до квадратної форми розміром 224×224 пікселі. Це стандартний формат, який використовується у більшості популярних архітектур, зокрема VGG, ResNet та EfficientNet. Процес масштабування зображення у формальному вигляді можна подати як операцію:

$$I'' = \text{Resize}(I', 224 \times 224) . \quad (2.7)$$

Оскільки вихідні дані подані в одному каналі (градації сірого), їх було дубльовано до формату RGB, який очікують більшість попередньо навчених CNN. Таким чином, остаточне представлення зображення має вигляд:

$$\hat{I}(x,y) = [I''(x,y), I''(x,y), I''(x,y)] . \quad (2.8)$$

У рамках роботи було виконано також візуальну перевірку результатів попередньої обробки. На рисунку 2.3 наведено приклад вихідного термографічного зображення дефектної панелі, а на рисунку 2.4 – той самий фрагмент після застосування всіх попередніх перетворень.

Оригінальне зображення, label=1




Рисунок 2.3 – Оригінальне інфрачервоне зображення фотоелектричної панелі
(label = 1)

Зображення після попередньої обробки (resize + RGB)




Рисунок 2.4 – Зображення після застосування resize та перетворення до RGB

Після масштабування та нормалізації було проведено аналіз якості обробки. Для цього будувалися випадкові вибірки зображень, які дозволили

оцінити ступінь збереження текстурних особливостей та чіткості термографічних патернів. Візуальний аналіз підтвердив, що наведені перетворення не спотворюють характерні ознаки дефектів, зокрема гарячі точки та перегріті сектори модулів, що особливо важливо у задачах автоматичної діагностики.

Загалом алгоритм попереднього опрацювання дозволив забезпечити однорідність даних, їхню коректну подачу на вхід нейронної мережі та зменшити вплив шуму й варіацій освітлення. Кожен етап обробки є важливим компонентом підготовчої частини моделювання, оскільки згорткові мережі особливо чутливі до правильного нормування та розмірності зображення.

2.4. Формування навчальної та тестової вибірок

Після завершення етапів підготовки й попередньої обробки термографічних зображень постало завдання сформувати навчальну та тестову вибірки таким чином, щоб зберегти репрезентативність даних і забезпечити коректну оцінку роботи моделі. У задачах класифікації дефектів фотоелектричних панелей важливо дотримуватися пропорцій між класами, оскільки навіть незначний дисбаланс впливає на збіжність моделі та призводить до зміщення прогнозів у бік домінуючого класу. Тому розділення даних виконували із застосуванням стратифікації, яка забезпечує однакову частку класів у навчальній та тестовій підвибірках.

Нехай початковий набір даних описується матрицями зображень:

$$X = \{x_1, x_2, \dots, x_n\}. \quad (2.9)$$

та вектором міток

$$Y = \{y_1, y_2, \dots, y_n\}, \quad y_i \in \{0, 1\}. \quad (2.10)$$

Операція стратифікованого поділу вибірки може бути формально подана як:

$$(X_{train}, X_{test}, Y_{train}, Y_{test}) = Split(X, Y, \alpha, stratify = Y). \quad (2.11)$$

де $\alpha = 0.2$ – частка тестової вибірки, а параметр stratify встановлює збереження початкового співвідношення класів у кожній підвибірці.

Результати поділу даних подані у таблиці 2.3. Видно, що співвідношення між класами «справна панель» та «дефектна панель» збереглося, що підтверджується й графічною візуалізацією (рисунки 2.5 і 2.6). Такий підхід використовується у сучасних роботах з діагностики PV-модулів, оскільки забезпечує стабільність під час навчання CNN [37].

Таблиця 2.3 – Структура навчальної та тестової вибірок

Показник	Навчальна вибірка	Тестова вибірка
Кількість зображень	2099	525
Клас 0 (справні)	1453	363
Клас 1 (дефектні)	646	162
Частка від загальної вибірки	80 %	20 %

Розподіл класів у підготовлених підвибірках подано на рисунках нижче. Вони демонструють, що кількість дефектних зразків у навчальній вибірці є меншою, ніж кількість справних, що характерно для реальних фотоелектричних установок, де появи дефектів трапляються значно рідше [3].




Рисунок 2.5 – Розподіл класів у тренувальній вибірці

Для подальшого навчання згорткової нейронної мережі було створено два набори `tf.data.Dataset`, які забезпечують ефективне пакетне завантаження зображень і підвищують швидкість тренування. Попередня обробка (`resize`, нормалізація, перетворення у формат RGB) застосовувалась до кожного зображення за допомогою функції `map`. Наведений нижче фрагмент коду ілюструє створення тренувального та тестового датасетів.




Рисунок 2.6 – Розподіл класів у тестовій вибірці

```
X_train, X_test, y_train, y_test = train_test_split(
    images, labels, test_size=0.2, random_state=42, stratify=labels
)

print("Train shape:", X_train.shape, "Test shape:", X_test.shape)

# Візуалізація розподілу класів у train/test
def plot_split_distribution(y_tr, y_te):
    unique_tr, count_tr = np.unique(y_tr, return_counts=True)
    unique_te, count_te = np.unique(y_te, return_counts=True)

    plt.figure()
    plt.bar(["train_0", "train_1"], count_tr)
    plt.title("Розподіл класів у тренувальній вибірці")
    plt.xlabel("Клас")
    plt.ylabel("Кількість")
    plt.show()

    plt.figure()
    plt.bar(["test_0", "test_1"], count_te)
    plt.title("Розподіл класів у тестовій вибірці")
    plt.xlabel("Клас")
    plt.ylabel("Кількість")
    plt.show()

plot_split_distribution(y_train, y_test)

train_ds = tf.data.Dataset.from_tensor_slices((X_train, y_train))
train_ds = train_ds.map(preprocess).shuffle(1000).batch(BATCH_SIZE).prefetch(tf.data.AUTOTUNE)
```

Рисунок 2.7 – Фрагмент коду формування train/test вибірок

Застосування механізмів shuffle, batch і prefetch забезпечило рівномірне перемішування даних, формування пакетів сталої величини та попереднє завантаження наступної порції зображень. Це дозволило скоротити час епохи навчання та уникнути «вузьких місць» у процесі читання даних, що підтверджується у роботах із застосуванням TensorFlow для обробки зображень у тепловізійній діагностиці [32].

Стратифікований поділ вибірки, збереження балансу між класами, використання ефективного конвеєра даних і попередня візуальна перевірка структури наборів забезпечили надійну основу для подальшого навчання моделі моніторингу стану фотоелектричних панелей із використанням згорткової нейронної мережі.

2.5. Вибір архітектур згорткових нейронних мереж для порівняльного аналізу

У процесі побудови інтелектуальної системи моніторингу технічного стану фотоелектричних установок важливо оцінити, яку саме архітектуру згорткової нейронної мережі доцільно застосувати для задачі класифікації термографічних зображень. Оскільки кожна архітектура CNN має різний ступінь складності, кількість параметрів, глибину мережі та здатність узагальнювати просторові закономірності, необхідно провести порівняльний аналіз декількох популярних моделей. Такий підхід відповідає рекомендаціям дослідників у галузі автоматичної діагностики PV-модулів, де ефективність CNN суттєво залежить від вибору архітектури.

Відповідно до поставленої задачі було відібрано п'ять архітектур, які добре зарекомендували себе в задачах комп'ютерного зору: базову мережу SimpleCNN та чотири глибокі моделі – MobileNetV2, VGG16, ResNet50V2 та EfficientNetB0. Кожна з них має власні особливості. SimpleCNN є компактною моделлю, побудованою спеціально для цієї роботи, що дозволяє швидко оцінити базовий

рівень складності задачі. Глибші архітектури, навчені на великому датасеті ImageNet, характеризуються значно більшою потужністю за рахунок попередньо вивчених фільтрів, здатних розпізнавати узагальнені просторові патерни. Формально будь-яку згорткову мережу можна представити як композицію перетворень:

$$f(X) = g_k(\dots g_2(g_1(X))). \quad (2.12)$$

де g_i – операції згортки, пулінгу, активації або нормалізації, які трансформують вихідні зображення у високорівневі ознаки.

Вибір архітектур обґрунтований необхідністю порівняти як моделі з малою кількістю параметрів (до 1 млн), так і великі мережі, здатні глибше аналізувати текстурні особливості термографічних зображень. У таблиці 2.4 наведено ключові характеристики обраних моделей, що дозволяє оцінити їхню теоретичну потужність до початку навчання.

Таблиця 2.4 – Характеристики обраних CNN-архітектур

Архітектура	Кількість параметрів	Тип мережі	Особливості
SimpleCNN	109 889	Базова, від початку навчена	Легка та швидка модель, використовується як орієнтир
MobileNetV2	≈2.2 млн	Тонка глибока мережа	Ефективна для мобільних пристроїв та малопотужних платформ
VGG16	≈15 млн	Глибока класична CNN	Має велику кількість параметрів і стабільну здатність до узагальнення
ResNet50V2	≈23 млн	Резидуальна мережа	Вирішує проблему зникнення градієнта завдяки skip-connections
EfficientNetB0	≈5.3 млн	Оптимізована модель нового покоління	Балансує точність і швидкодію за рахунок компаундинг-скейлінгу

Для подальшої роботи було реалізовано програмну генерацію зазначених архітектур у середовищі TensorFlow. Кожна модель створюється окремою функцією, що дозволяє порівнювати їх без змін у навчальному циклі. Фрагмент

коду наведено нижче і демонструє підхід до побудови моделей. Основою є використання попередньо навчених мереж з вимкненими базовими вагами (`trainable=False`), що дозволяє зосередитися на класифікаційній частині, адаптованій до задачі виявлення дефектів.

```
def build_simple_cnn(input_shape=(IMG_SIZE, IMG_SIZE, 3)):
    inputs = Input(shape=input_shape)
    x = layers.Conv2D(32, (3, 3), activation="relu", padding="same")(inputs)
    x = layers.MaxPooling2D()(x)
    x = layers.Conv2D(64, (3, 3), activation="relu", padding="same")(x)
    x = layers.MaxPooling2D()(x)
    x = layers.Conv2D(128, (3, 3), activation="relu", padding="same")(x)
    x = layers.GlobalAveragePooling2D()(x)
    x = layers.Dense(128, activation="relu")(x)
    x = layers.Dropout(0.3)(x)
    outputs = layers.Dense(1, activation="sigmoid")(x)
    model = models.Model(inputs, outputs, name="SimpleCNN")
    return model

def build_mobilenet(input_shape=(IMG_SIZE, IMG_SIZE, 3)):
    base = MobileNetV2(
        input_shape=input_shape,
        include_top=False,
        weights="imagenet",
        pooling="avg"
    )
    base.trainable = False
    inputs = Input(shape=input_shape)
    x = base(inputs, training=False)
    x = layers.Dense(128, activation="relu")(x)
    x = layers.Dropout(0.3)(x)
    outputs = layers.Dense(1, activation="sigmoid")(x)
    model = models.Model(inputs, outputs, name="MobileNetV2")
    return model
```

Рисунок 2.8 – Фрагмент коду формування набору CNN-архітектур

Приклад структури однієї з побудованих моделей (SimpleCNN) наведено на рисунку 2.9. Вона складається з трьох блоків згортки та пулінгу, операції глобального середнього пулінгу, двох щільних шарів та шару Dropout, який зменшує ризик перенавчання. На відміну від великих моделей, SimpleCNN має відносно невелику кількість параметрів і може слугувати еталоном для порівняння.

Model: "SimpleCNN"

Layer (type)	Output Shape	Param #
input_layer_10 (InputLayer)	(None, 128, 128, 3)	0
conv2d_6 (Conv2D)	(None, 128, 128, 32)	896
max_pooling2d_7 (MaxPooling2D)	(None, 64, 64, 32)	0
conv2d_7 (Conv2D)	(None, 64, 64, 64)	18,496
max_pooling2d_8 (MaxPooling2D)	(None, 32, 32, 64)	0
conv2d_8 (Conv2D)	(None, 32, 32, 128)	73,856
global_average_pooling2d_4 (GlobalAveragePooling2D)	(None, 128)	0
dense_12 (Dense)	(None, 128)	16,512
dropout_6 (Dropout)	(None, 128)	0
dense_13 (Dense)	(None, 1)	129

Total params: 109,889 (429.25 KB)

Trainable params: 109,889 (429.25 KB)

Non-trainable params: 0 (0.00 B)

Рисунок 2.9 – Архітектура нейронної мережі SimpleCNN

Основною метою цього етапу було порівняти різні підходи до екстрагування ознак і визначити, яка архітектура найбільш ефективно аналізує термографічні зображення фотоелектричних панелей. Вибір моделей різної складності забезпечив можливість комплексного аналізу продуктивності, стабільності та швидкодії. У подальших розділах буде наведено результати навчання цих мереж та їх порівняння за метриками точності, повноти та швидкодії, що дозволить обґрунтовано вибрати найкращу архітектуру для побудови системи моніторингу стану фотоелектричних установок.

2.6. Проведення навчання моделей та оцінювання їхньої ефективності

Після вибору архітектур згорткових нейронних мереж було проведено серію експериментів з їх навчання на підготовлених термографічних зображеннях фотоелектричних панелей. Для всіх моделей застосовано єдину

схему налаштування гіперпараметрів, що дало змогу коректно порівнювати результати. Як функцію втрат використано бінарну кросентропію, а для оптимізації ваг нейронної мережі – алгоритм Adam з кроком навчання 10^{-4} . Навчання кожної архітектури виконувалося протягом п'яти епох із використанням батчів фіксованого розміру, сформованих із навчальної вибірки. Для оцінювання якості моделей у процесі тренування застосовувалися показники точності (ассигасу) на валідаційному піднаборі, отриманому з тестової вибірки [1].

Формально задача навчання мережі розглядається як мінімізація функції втрат:

$$L(\theta) = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (2.13)$$

де y_i – істинна мітка класу; $\hat{y}_i$ – прогнозована ймовірність дефектної панелі; θ – вектор параметрів моделі; N – кількість зразків у батчі.

Оптимізація відбувалася шляхом послідовного оновлення параметрів за методом стохастичного градієнтного спуску в модифікації Adam. Після завершення навчання для кожної архітектури було проведено тестування на відкладеній вибірці та обчислено метрики точності, повноти, точності позитивного прогнозу та F1-міри.

На рисунках 2.10 наведено приклад динаміки точності та значення функції втрат для базової архітектури SimpleCNN. Подібні графіки побудовано для всіх інших моделей, при цьому для кожної з них на одному рисунку відображено дві криві – для тренувальної й валідаційної вибірок. Аналіз графіків показав, що для SimpleCNN спостерігається повільне зростання точності до рівня близько 0,69, а функція втрат монотонно зменшується, проте досить повільно. Це свідчить про обмежену потужність базової архітектури та її схильність до недонавчання, що є очікуваним для моделі з відносно невеликою кількістю параметрів.




Рисунок 2.10 – Динаміка точності (accuracy) та функції втрат (loss) для моделі SimpleCNN

Для глибших архітектур, зокрема MobileNetV2 та ResNet50V2, графіки демонстрували швидке зростання точності вже з перших епох, а значення функції втрат зменшувалися істотно інтенсивніше, ніж у SimpleCNN. При цьому валідаційні криві майже не відставали від тренувальних, що свідчить про відсутність яскраво вираженого перенавчання. У випадку VGG16 покращення якості також було помітним, але ціною значного збільшення часу тренування: одна епоха для VGG16 тривала в декілька разів довше, ніж для MobileNetV2. Архітектура EfficientNetB0 у проведених експериментах показала середні результати, її точність на тестовій вибірці залишилася близькою до базової SimpleCNN, хоча динаміка втрат свідчила про поступове, але не дуже виразне покращення.

У таблиці 2.5 наведено узагальнені результати тестування всіх п'яти моделей. Таблиця містить значення точності, точності позитивного прогнозу, повноти, F1-міри та орієнтовний час навчання. Показники обчислено на відкладеній вибірці з використанням стандартних визначень:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad (2.14)$$

$$Precision = \frac{TP}{TP + FP}, \quad Recall = \frac{TP}{TP + FN}, \quad (2.15)$$

$$F_1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}, \quad (2.16)$$

де TP – кількість правильно класифікованих дефектних панелей; TN – кількість правильно класифікованих справних панелей; FP та FN – помилкові позитивні та помилкові негативні класифікації відповідно.

Таблиця 2.5 – Порівняння ефективності CNN-архітектур на тестовій вибірці

Модель	Accuracy	Precision	Recall	F1-міра	Час навчання, хв
SimpleCNN	0,69	0,62	0,41	0,49	≈ 7
MobileNetV2	0,85	0,83	0,74	0,78	≈ 3
VGG16	0,76	0,71	0,58	0,64	≈ 40
ResNet50V2	0,85	0,80	0,77	0,78	≈ 12
EfficientNetB0	0,69	0,63	0,46	0,53	≈ 6

Для відтворюваності експериментів у звіті наведено ключовий фрагмент коду, який реалізує цикл навчання всіх моделей, збір статистики та побудову графіків. Саме ця процедура лягла в основу отриманих результатів.

```

results = []
histories = {}

for name, builder in architectures.items():
    print(f"\n=====")
    print(f"Навчання моделі: {name}")
    print(f"=====")

    model = builder()
    model.compile(
        optimizer=tf.keras.optimizers.Adam(1e-4),
        loss="binary_crossentropy",
        metrics=["accuracy"]
    )

    start_time = time.time()
    history = model.fit(
        train_ds,
        validation_data=test_ds,
        epochs=EPOCHS,
        verbose=1
    )
    train_time = time.time() - start_time

    histories[name] = history.history

    y_pred_prob = model.predict(test_ds).ravel()
    y_pred = (y_pred_prob >= 0.5).astype(int)

    acc = accuracy_score(y_test, y_pred)
    prec = precision_score(y_test, y_pred, zero_division=0)

```

Рисунок 2.11 – Фрагмент коду навчання моделей та побудова кривих навчання

Аналіз отриманих результатів показав, що найвищу точність та найкраще співвідношення між точністю і повнотою продемонстрували архітектури MobileNetV2 та ResNet50V2. При цьому MobileNetV2 виявилася помітно швидшою в навчанні, що робить її більш привабливою для практичних систем моніторингу, які можуть використовуватися в умовах обмежених обчислювальних ресурсів. Базова модель SimpleCNN та EfficientNetB0 продемонстрували приблизно однаковий рівень точності, який можна розглядати як відправну точку для порівняння. Отже, результати цього етапу слугуватимуть основою для подальшого вибору найкращої архітектури згорткової нейронної мережі, що буде використана в інтегрованій системі моніторингу стану фотоелектричних установок.

2.7. Порівняльний аналіз результатів навчання за метриками точності, повноти та швидкодії

Після завершення процесу навчання п'яти згорткових архітектур було виконано порівняльний аналіз їхньої продуктивності за низкою узагальнених метрик: точність (*accuracy*), точність позитивного класу (*precision*), повнота (*recall*), узагальнена міра *F1* та час навчання. Такий багатокритеріальний підхід дозволив комплексно оцінити поведінку моделей за умов нерівномірного розподілу класів і різної складності архітектури.

У таблиці 2.6 подано синтезовані результати аналізу отриманих моделей.

Таблиця 2.6 – Порівняльні результати моделей CNN

Модель	Accuracy	Precision	Recall	F1	Train time, s
MobileNetV2	0.8514	0.8308	0.6585	0.7347	202.97
ResNet50V2	0.8476	0.9468	0.5427	0.6899	728.31
VGG16	0.7581	0.9111	0.2500	0.3923	2593.37
SimpleCNN	0.6933	1.0000	0.0183	0.0359	418.20
EfficientNetB0	0.6876	0.0000	0.0000	0.0000	351.56

На основі таблиці видно, що найвищий показник точності демонструє MobileNetV2, яка виявила оптимальне співвідношення між кількістю параметрів і узагальнювальною здатністю. Архітектура ResNet50V2 показала найбільшу точність позитивного класу, однак поступилася за повнотою, що вплинуло на зниження F1-міри. Модель VGG16 продемонструвала задовільну точність, але через значну обчислювальну складність її навчання тривало найдовше, що робить її менш доцільною для оперативних систем моніторингу. Простіший SimpleCNN бракує здатності коректно виявляти дефектні панелі, що підтверджується надзвичайно низькою повнотою. Модель EfficientNetB0 у даному експерименті не змогла адаптуватися до специфіки термографічних зображень і фактично не розпізнавала позитивний клас.




Рисунок 2.12 – Порівняння моделей за різними метриками

Для кращої інтерпретації були побудовані графічні порівняння за кожною метрикою. На рисунку 2.12 наведено порівняння моделей за точністю.

Аналіз рисунка показує, що дві моделі MobileNetV2 та ResNet50V2 значно перевершують інші архітектури, демонструючи точність понад 0.84.

ResNet50V2 досяг найвищої точності класифікації позитивного класу. Це означає, що модель майже не допускає хибнопозитивних спрацьовувань. Однак високий precision не гарантує високої recall, тому така модель може пропускати частину дефектів.

MobileNetV2 демонструє найвищий рівень recall, тобто найменше пропускає дефектів. Для задач технічної діагностики цей показник є критичним, адже важливо не пропустити потенційно небезпечну несправність.

Саме MobileNetV2 виявила найкраще співвідношення точності та повноти, тому F1-міра становить 0.7347, що є найбільшим значенням серед порівнюваних архітектур.

MobileNetV2 є не лише якіснішою, а й найшвидшою із трійки лідерів. VGG16 виявилася найбільш ресурсоємною та потребувала понад 2500 секунд.

Підсумовуючи, результати порівняльного аналізу показують, що найраціональнішим вибором для системи моніторингу технічного стану фотоелектричних панелей є модель MobileNetV2. Вона поєднує високу точність, високу повноту, найкращу узагальнювальну здатність та найменший час навчання серед моделей з високою якістю класифікації.

Після виконання серії експериментів, що охоплювали навчання та тестування п'яти різних архітектур згорткових нейронних мереж, постало питання вибору оптимальної моделі для практичного застосування у системі моніторингу технічного стану фотоелектричних панелей. Для ухвалення остаточного рішення були проаналізовані значення основних метрик, які найбільш точно характеризують якість класифікації в задачах виявлення дефектів: accuracy, precision, recall та узагальнена міра F1. Додатково враховувався час навчання, оскільки надмірно обчислювально-складні моделі можуть бути менш придатними для оперативного розгортання.

На основі узагальнених результатів (табл. 2.6) видно, що найвищий показник точності продемонструвала MobileNetV2, значення якої становить 0.8514. Хоча ResNet50V2 показала близьке значення accuracy, вона поступилася за показником повноти, що є критично важливим у діагностичних системах. Архітектура VGG16, попри задовільну точність, характеризувалася найтривалішим часом навчання і значно гіршою здатністю виявляти дефекти. Простіша модель SimpleCNN показала недостатню повноту, а EfficientNetB0 у рамках цього експерименту не продемонструвала здатності до розпізнавання позитивного класу.

Особливу увагу було приділено значенню F1-міри, оскільки вона враховує як точність, так і повноту, що є важливим для зменшення кількості пропущених дефектів. Максимальна F1-оцінка належить моделі MobileNetV2, яка досягла значення 0.7347. Такий результат свідчить про її збалансованість і стабільну роботу на тестовій вибірці. Водночас час навчання цієї архітектури – лише 203 секунди, виявився найменшим серед тих моделей, що демонстрували високу якість класифікації. Це робить MobileNetV2 не лише ефективною, а й ресурсно ощадною.

За результатами аналізу можна стверджувати, що саме MobileNetV2 найповніше відповідає вимогам системи моніторингу технічного стану фотоелектричних установок. Її архітектура, оптимізована для мобільних і вбудованих застосувань, забезпечує високу точність класифікації при мінімальних обчислювальних витратах, а також стійкість до різноманітних особливостей термографічних зображень. Тому саме ця модель обрана як основа для подальшої інтеграції у розроблювану інтелектуальну систему моніторингу.

РОЗДІЛ 3.

РЕЗУЛЬТАТИ ПРОЄКТУВАННЯ ТА СТВОРЕННЯ ІНФОРМАЦІЙНОЇ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ МОНІТОРИНГУ СТАНУ ФОТОЕЛЕКТРИЧНИХ УСТАНОВОК

3.1. Загальна структура інформаційної системи моніторингу

Загальна архітектура розробленої інформаційної системи підтримки прийняття рішень (ІСППР) орієнтована на безперервне отримання, обробку та аналітичну інтерпретацію зображень фотоелектричних панелей, отриманих із дронів або стаціонарних технічних засобів контролю. Основою побудови системи є модульний підхід, у межах якого окремі компоненти виконують локальні функції, але взаємодіють через чітко визначені інтерфейси. Завдяки цьому забезпечується можливість швидкого оновлення алгоритмів, адаптації під інше обладнання та масштабування обсягів вхідних даних без зміни загальної логіки роботи.

Структура ІСППР поділяється на три рівні. Перший рівень формує вхідний шар збору даних, де відбувається передавання зображень до серверної частини. Наступний рівень, який виконує функцію інтелектуального аналізу, містить нейромережеві моделі, оптимізовані під класифікацію станів фотоелектричних модулів. На завершальному рівні реалізовано компоненти взаємодії з оператором, що виводять результат оцінювання, формують пояснювальні повідомлення й дозволяють зберігати діагностичні звіти у стандартизованому форматі. Такий підхід забезпечує узгодженість роботи системи як у режимі локального використання, так і в разі інтеграції з ширшим комплексом моніторингу енергетичних об'єктів.

Функціональні модулі системи та їх роль наведено в таблиці 3.1. У ній узагальнено призначення кожного компонента, а також логіку його включення в загальний цикл роботи алгоритму.

Таблиця 3.1 – Структурні модулі ІСППР та їх функціональні призначення

Модуль	Функціональне призначення
Модуль завантаження зображень	Приймає зображення з дронів або з локального сховища та виконує попередню обробку
Модуль нейромережевого аналізу	Застосовує модель класифікації (MobileNetV2) для оцінювання стану панелі
Модуль інтерпретації результатів	Перетворює прогноз моделі на висновки щодо наявності пошкоджень
Інтерфейс користувача	Забезпечує візуалізацію, формування звітів та інтерактивну взаємодію
Модуль передачі діагностичних повідомлень	Ініціює надсилання оцінок оператору моніторингової станції

Загальну логіку функціонування системи ілюструє рисунок 3.1, на якому схематично подано послідовність обробки та передачі даних. Вхідний потік із дронів або камер потрапляє до етапу нормалізації, де відбувається перетворення зображення до необхідних параметрів. Після цього дані спрямовуються до нейромережі, яка відносить панель до класу «норма» або «можливе пошкодження». Фінальний етап включає відображення результату та формування короткого текстового звіту.




Рисунок 3.1 – Узагальнена схема потоків даних інформаційної системи моніторингу

Важливим елементом архітектури є веб-інтерфейс, який реалізовано за допомогою середовища Streamlit. Завдяки цьому система доступна користувачам без додаткового програмного забезпечення, а сама логіка взаємодії нагадує

типові інструменти аналітичної діагностики. На рисунку 3.2 подано приклад структурного компонування інтерфейсу, що містить блоки завантаження зображення, кнопки запуску аналізу, секцію із прогностичним висновком та вікно аналітичної інформації.

```
st.subheader("📷 Завантаження зображення з дрона")

uploaded_file = st.file_uploader("Завантажте фото:", type=["jpg", "png", "jpeg"])

def prepare_image(img):
    img = img.resize((128, 128))
    img_array = np.array(img) / 255.0
    return np.expand_dims(img_array, axis=0)

if uploaded_file:
    image = Image.open(uploaded_file).convert("RGB")

    col1, col2 = st.columns(2)

    with col1:
        st.image(image, caption="Вхідне зображення", use_column_width=True)
```

Рисунок 3.2 – Фрагмент коду, що відповідає за завантаження моделі та взаємодію інтерфейсу з користувачем

У режимі реального часу прогнозування виконується протягом часток секунди, що забезпечується оптимізацією розміру вхідного зображення та попередньо навченими вагами моделі MobileNetV2. Після аналізу система виводить як текстовий висновок, так і числові ймовірності класів, які дають змогу оператору самостійно оцінити ступінь достовірності прогнозу та ухвалити рішення щодо подальших дій.

Загальна структура системи створює цілісну основу для подальшої інтеграції в комплекс енергетичного моніторингу та дозволяє автоматизувати процес виявлення пошкоджених фотоелектричних панелей у складних умовах експлуатації. Завдяки відкритій архітектурі та модульній організації система може бути доповнена додатковими алгоритмами, включаючи сегментаційні моделі, системи визначення локалізації дефектів та механізми прогнозування деградації панелей на основі тимчасових рядів.

3.2. Архітектура програмного комплексу ІСППР

Архітектура програмного комплексу створено таким чином, щоб забезпечити цілісність обробки зображень та стабільність під час роботи в умовах різного навантаження. Основою реалізації стала трирівнева модель побудови системи, де кожен рівень виконує окремий фрагмент логіки, але водночас залишається взаємопов'язаним з іншими через внутрішні API. Така структура дозволяє розгортати програмний комплекс як на локальній станції, так і на хмарній інфраструктурі без зміни фундаментальних механізмів взаємодії модулів.

У межах першого рівня функціонує інтерфейс користувача, який відповідає за завантаження вхідних зображень та ініціалізацію аналізу. Другий рівень формує аналітичну частину, що включає підготовку даних, запуск нейромережевого класифікатора та розрахунок прогнозу. Заключна частина призначена для збереження та формування діагностичних матеріалів, включно з автоматично створеним звітом, який може бути надіслано оператору або збережено для подальшої оцінки. Така організація процесів дає змогу працювати з потоковими даними, не перевантажуючи обчислювальні ресурси користувача.

Загальну структуру програмного комплексу подано на рисунку 3.3. Архітектурна схема побудована в умовному форматі «architecture-beta», який дозволяє виразно представити логічні блоки та їх взаємозв'язки.

Архітектурна модель, подана на рисунку, демонструє узгоджену роботу всіх модулів та їх взаємоспрямованість. Компоненти інтерфейсу взаємодіють із ядром системи через виклики, що ініціюють аналіз зображення, тоді як аналітичні модулі забезпечують обчислення прогнозу та передають інтерпретовані результати у блок звітності. Механізм повідомлення дозволяє оперативно реагувати на потенційно критичні ситуації, що особливо важливо для об'єктів фотоенергетики, розташованих у віддалених місцях або на промислових платформах.




Рисунок 3.3 – Архітектура програмного комплексу ІСППР

Окрему увагу в архітектурі приділено оптимізації взаємодії між обчислювальними компонентами. Завдяки чіткому розподілу ролей між попередньою обробкою зображень та нейромережею вдалося мінімізувати час прогнозування. Це забезпечує можливість аналізувати значні набори знімків без затримок. Для демонстрації внутрішньої логіки роботи ядра наведено фрагмент програмного коду, який відповідає за виконання класифікації та передавання результату в модуль інтерпретації.

У такий спосіб отриманий прогноз одразу спрямовується в блок формування висновку, що робить обробку зображення фактично одноетапною з точки зору користувача. У разі інтеграції з реальним виробничим середовищем архітектура може бути розширена додатковими сервісами, зокрема модулями

геолокаційної прив'язки або компонентами обліку статистики деградації фотоелектричних панелей.

```

if uploaded_file:
    image = Image.open(uploaded_file).convert("RGB")

    col1, col2 = st.columns(2)

    with col1:
        st.image(image, caption="Вхідне зображення", use_column_width=True)

    with col2:
        st.info("▶ Натисніть кнопку нижче для аналізу")

    if st.button("🔍 Проаналізувати стан"):
        img_batch = prepare_image(image)
        prediction = model.predict(img_batch)[0][0]

        if prediction > 0.5:
            result = "⚠ Виявлено можливе пошкодження панелі"
            color = "red"
        else:
            result = "✅ Стан фотоелектричної установки: НОРМА"
            color = "green"

    st.markdown(
        f"<h2 style='color:{color}'; text-align:center;'>{result}</h2>",
        unsafe_allow_html=True
    )

```

(variable) result: Literal['⚠ Виявлено можливе пошкодження панелі', '✅ Стан фотоелектричної установки: НОРМА']

Рисунок 3.4 – Фрагмент коду демонстрації внутрішньої логіки роботи ядра

Таким чином, структура програмного комплексу забезпечує необхідний баланс між швидкістю, модульністю та можливістю подальшого масштабування системи. Його компоненти створюють інтелектуальну основу для автоматизованого моніторингу стану фотоелектричних установок та формування оперативних рекомендацій для інженерних підрозділів.

На концептуальному рівні архітектура складається з трьох основних блоків. Перший блок відповідає за представлення користувацького інтерфейсу, який реалізовано як веб-додаток за допомогою Streamlit. Другий блок охоплює аналітичний модуль, що включає неймережеві моделі для класифікації станів панелей. Третій блок забезпечує збереження, формування та передачу діагностичних звітів. Логіка взаємодії цих компонентів базується на принципах асинхронності, що дозволяє уникнути затримок під час оброблення великих наборів зображень, отриманих із дронів або з наземних камер моніторингу.

Загальну схему архітектури програмного комплексу подано на рисунку 3.5. У ній показано ключові модулі системи, а також основні шляхи обміну інформацією між ними. Кожний модуль виконує власне функціональне завдання, проте всі компоненти формують єдине середовище інтелектуальної діагностики.




Рисунок 3.5 – Архітектурна схема програмного комплексу ІСППР

Функціональний зміст основних компонентів системи узагальнено в таблиці 3.2, де наведено призначення модулів та короткий опис їх реалізації. Така форма представлення дозволяє швидко оцінити структуру програмного комплексу та зрозуміти його внутрішню логіку.

Таблиця 3.2 – Основні компоненти архітектури програмного комплексу ІСППР

Компонент	Призначення	Принцип реалізації
Інтерфейс Streamlit	Забезпечення взаємодії з користувачем	Веб-застосунок із можливістю завантаження зображень і перегляду результатів
Модуль підготовки даних	Нормалізація та масштабування зображень	Зміна розміру, перетворення в масив пікселів, нормування
Нейромережевий класифікатор	Виявлення пошкоджень панелей	Використання моделі MobileNetV2, натренованої на двокласовій вибірці
Модуль інтерпретації	Перетворення ймовірності моделі у зрозумілий висновок	Формування повідомлення «норма» або «пошкоджено»
Модуль звітності	Створення текстових діагностичних документів	Генерація файлів <i>.txt</i> з параметрами прогнозу
Модуль передачі сигналів	Інформування оператора про критичні стани	Симульоване або реальне сповіщення (email / API)

Програмна частина аналітичного ядра забезпечує зв'язок між інтерфейсом та нейромережею, виконуючи ключові обчислення. Для демонстрації взаємодії між ядром і веб-інтерфейсом наведено компактний фрагмент коду, що відповідає за передавання зображення та запуск алгоритму класифікації.

Окремо варто зазначити, що для підвищення надійності було застосовано кешування моделі за допомогою декоратора `@st.cache_resource`. Це дозволяє уникнути повторного завантаження важкої нейронної структури при кожному оновленні сторінки, що суттєво пришвидшує роботу застосунку та знижує навантаження на процесор або графічний прискорювач. Власне модель

завантажується лише один раз, тоді як подальші запити використовують її збережений стан.

Програмний комплекс побудований таким чином, щоб зберігати гнучкість для подальших доопрацювань. При необхідності до нього можуть бути додані додаткові аналітичні модулі, зокрема моделі сегментації дефектів, блоки геопросторової прив'язки або модулі статистичного аналізу для агрегованих даних із кількох моніторингових станцій. Така відкритість дозволяє легко інтегрувати ІСППР у широкий спектр енергетичних інтелектуальних систем, орієнтованих на підвищення безпеки та ефективності фотоелектричних установок.

3.3. Модулі збору, зберігання та аналітичної обробки даних

Функціонування інтелектуальної системи моніторингу стану фотоелектричних установок передбачає безперервне надходження, збереження та опрацювання даних, що отримуються від дронів, наземних камер або інших джерел візуальної інформації. Модульна організація цієї підсистеми забезпечує гнучкість, стійкість до помилок та можливість масштабування у разі збільшення кількості сонячних панелей або підключення додаткових сенсорних платформ. Кожний модуль має власну функцію, але працює в інтегрованому середовищі, утворюючи безперервний конвеєр обробки даних – від первинного збору до аналітичного висновку моделі класифікації.

Основу такої підсистеми складають три ключові компоненти: модуль збору даних, модуль зберігання та модуль аналітичної обробки. Перший відповідає за приймання даних у режимі реального часу, другий – за їх структуроване розміщення та підготовку до подальшого використання, третій – за виконання алгоритмів оцінювання технічного стану фотоелектричних панелей на основі глибинних нейронних мереж. Спільне використання цих компонентів формує

єдиний інформаційний простір, у якому дані проходять повний життєвий цикл від їх надходження до формування діагностичних висновків.




Рисунок 3.6 – Узагальнена структура модулів збору, зберігання та обробки даних

Схема демонструє послідовний рух зображень від моменту їхнього отримання до формування аналітичного висновку. Кожний блок позначає окремий модуль, що взаємодіє з іншими через стандартизовані інтерфейси.

Таблиця 3.3 – Характеристика основних модулів системи

Модуль	Основна функція	Тип даних	Рівень навантаження
Data Ingestion	Приймання та первинна валідація даних	зображення JPEG/PNG	високий при потоковому зборі
Raw Storage	Збереження повнорозмірних знімків	бінарні файли	середній
Temporary Cache	Форматування та підготовка вибірки	нормалізовані матриці	високий під час аналізу
Preprocessing Unit	Масштабування, фільтрація, корекція	тензори 128×128×3	високий
Classifier Engine	Класифікація стану панелі	ймовірність/клас	високий
Result Interpreter	Формування висновку	текст/структуровані дані	низький

Така форма представлення дозволяє зіставити логічні та технічні властивості кожного модуля та оцінити їхню роль у загальній архітектурі.

Функціонування підсистеми аналітики ґрунтується на послідовному виконанні кількох алгоритмічних етапів. Первинний підхід передбачає нормалізацію даних, їх масштабування до стандартного розміру, усунення шумових компонентів і перетворення до формату, який може бути безпосередньо переданий у модель MobileNetV2. Далі активується блок глибинної нейронної мережі, який на основі внутрішніх узагальнених ознак виконує класифікацію, повертаючи числовий прогноз можливості пошкодження.

Нижче наведено фрагмент реального коду з модуля попередньої обробки, який використовується в системі (рис. 3.7).

```
import numpy as np
from PIL import Image

def preprocess_image(img: Image.Image):
    img = img.resize((128, 128))
    arr = np.array(img).astype("float32") / 255.0
    return np.expand_dims(arr, axis=0)
```

Рисунок 3.7 – Фрагмент коду з модуля попередньої обробки, який використовується в системі

Цей код ілюструє, як зображення перетворюється на тензор, придатний для аналізу моделлю глибокого навчання. Після цього згенерований масив передається до класифікатора:

$$prediction = model.predict(processed_image)[0][0].$$

Після отримання прогнозу виконується інтерпретація на рівні операторського інтерфейсу. Система визначає не лише факт наявності пошкодження, а й надає кількісну оцінку, що дозволяє врахувати рівень впевненості моделі. Цей підхід важливий у системах моніторингу, де оператор потребує чіткого розуміння можливої помилки моделі.

Комплекс модулів збору, зберігання та обробки даних забезпечує послідовний і структурований потік інформації, на основі якого формуються аналітичні висновки щодо технічного стану фотоелектричних панелей. Така модульна організація дає змогу масштабувати систему, підключати нові джерела даних та оптимізувати алгоритмічні процедури глибинного аналізу.

3.4. Інтеграція результатів згорткової нейронної мережі в систему моніторингу

Інтеграція прогнозів згорткової нейронної мережі в архітектуру ІСППР дає можливість автоматизувати процес технічної діагностики фотоелектричних установок та забезпечити своєчасне виявлення потенційно небезпечних пошкоджень. Після проходження зображенням модулів попередньої обробки модель формує числовий прогноз, який відображає ймовірність того, що на панелі присутні дефекти. Це значення надходить у модуль інтерпретації, де перетворюється у висновок, придатний для подальшого використання в операторському інтерфейсі, системі сповіщення та звітних формах. Такий підхід дозволяє не лише автоматизувати процес аналізу, а й зменшити залежність від людського чинника, що є критично важливим при обробці великих потоків даних, отриманих із дронів або інших сенсорних платформ.




Рисунок 3.8 – Інтеграційний блоковий ланцюжок приймання рішення

Схема демонструє, як числовий результат моделі проходить через інтерпретаційний рівень і перетворюється у кінцевий висновок, що відображається оператору системи.

Таблиця 3.4 – Структура інтеграційного процесу

Етап	Компонент	Тип даних	Опис
1	Probability Score	float	Значення від 0 до 1, сформоване нейронною мережею
2	Binary Decision	int (0/1)	Попередня інтерпретація стану панелі
3	Risk Mapping	float	Нормалізація та зважування ризику
4	Status Generator	text	Формування статусу «Норма» або «Пошкоджено»
5	Alert Module	text + event	Створення сповіщення у разі підвищеного ризику

Така структура дозволяє трактувати результат моделі як частину ширшої логіки приймання рішень, що підвищує гнучкість системи.

Після виконання прямого проходження моделі згорткової мережі формується масив ймовірностей. Для поточної реалізації, що передбачає бінарну класифікацію стану панелі, використовується лише одне значення – оцінка ризику пошкодження.

Для інтеграції застосовується порогова функція:

$$f(x) = \begin{cases} 1, & x \geq \tau \\ 0, & x < \tau \end{cases} \quad (3.1)$$

де x – прогноз моделі; $\tau = 0.5$ – базовий поріг прийняття рішення.

У разі необхідності поріг може бути адаптований шляхом калібрування, що дозволяє підлаштувати чутливість системи під конкретні характеристики обладнання.

Після формування класу відбувається його інтерпретація у термінах, зрозумілих оператору (рис. 3.4).

У Streamlit-інтерфейсі, що використовується в ІСППР, блок інтеграції автоматично передає результат у компоненти візуалізації та сповіщення.

Використання індикаторів, метрик і шкали прогресу дає змогу оператору швидко оцінити рівень ризику та прийняти подальші рішення щодо обстеження або ремонту установки.

При перевищенні встановленого порогу система активує модуль сповіщень. Цей модуль може передавати сигнал оператору моніторингової станції або ініціювати автоматичне формування звіту.

У такому вигляді інтеграція нейронної мережі виходить за межі простого прогнозування, забезпечуючи логічно завершений цикл, який включає аналіз, інтерпретацію, передачу та архівацію результатів.

Інтеграція результатів згорткової нейронної мережі у систему моніторингу перетворює процес діагностики фотоелектричних установок на автоматизований і повністю керований потоками даних. Такий підхід дозволяє істотно знизити час реагування на критичні зміни, підвищити точність аналізу та забезпечити сталість роботи системи навіть у разі обробки великих потоків зображень. Завдяки поєднанню глибинних моделей із модулем інтерфейсу та механізмом сповіщення система набуває властивостей повноцінного інтелектуального інструменту для технічного моніторингу.

3.5. Інтерфейс користувача та візуалізація результатів діагностики

Інтерфейс користувача відіграє ключову роль у забезпеченні практичної цінності інтелектуальної системи моніторингу, оскільки саме через нього оператор взаємодіє з інструментом діагностики та отримує доступ до аналітичних висновків моделі глибокого навчання. Під час розроблення інтерфейсу головними принципами були інтуїтивність, зрозуміла навігація та можливість максимально швидкого сприйняття інформації про технічний стан фотоелектричних панелей. Саме тому акцент було зроблено на мінімалістичному komponуванні елементів, використанні великої кількості простору та застосуванні контрастних акцентів для позначення діагностичних висновків.

Функціональний сценарій роботи інтерфейсу передбачає кілька послідовних кроків: завантаження зображення з дрона, його попередній перегляд, ініціацію аналізу та перегляд результатів оцінки. Інформація подається у візуально структурованому вигляді з використанням кольорових маркерів, метрик та графічних елементів, що дозволяє оператору швидко зреагувати на сповіщення та, за необхідності, сформулювати звіт.




Рисунок 3.9 – Логіка роботи інтерфейсу користувача

Схема (рис. 3.9) відображає основні кроки взаємодії користувача з системою та логіку переходів між блоками. Кожен із цих кроків реалізований у Streamlit-інтерфейсі у вигляді окремого елемента управління.

Таблиця 3.5 – Основні UI-компоненти та їх функціональне призначення

Компонент інтерфейсу	Призначення	Формат даних
Завантажувач зображень	Приймає файл від користувача	JPEG, PNG
Попередній перегляд	Відображає вхідне зображення	растрове зображення
Кнопка «Проаналізувати стан»	Ініціює виклик моделі	подія
Блок результатів	Містить метрики та статус	текст + числові значення
Гістограма ризику	Візуалізує рівень впевненості моделі	прогрес-бар
Модуль звітності	Генерує текстовий звіт	txt-файл
Сповіщення	Інформує оператора про критичний стан	текст + іконка

Така структура сприяє сприйняттю інформації та мінімізації часу на аналіз отриманої діагностики.

Інтерфейс користувача інтелектуальної системи моніторингу побудований таким чином, щоб забезпечити оператору просту навігацію, швидке завантаження зображень та інтуїтивну інтерпретацію результатів. Головний екран містить заголовок системи, інструкцію щодо завантаження зображення та блок для імпорту файла з дрона. На рисунку 3.9 подано вигляд початкової сторінки інтерфейсу, що відображається після запуску системи через вебінтерфейс.




Рисунок 3.10 – Головне вікно системи з модулем завантаження зображення

Після завантаження даних користувач отримує можливість попереднього перегляду зображення перед запуском аналізу. Це дозволяє переконатися у коректності вибраного файла й уникнути помилок, пов'язаних з якістю чи невідповідністю формату. Візуалізація попереднього перегляду представлена на наступному рисунку.




Рисунок 3.11 – Попередній перегляд зображення сонячної панелі перед аналізом

Після натискання кнопки «Проаналізувати стан» система виконує повний цикл обробки зображення, запускає модель глибокого навчання та виводить числові метрики ймовірності несправності та норми. У разі виявлення пошкодження користувач отримує помітне текстове попередження, а також може завантажити згенерований звіт та ознайомитися з аналітичними даними.




Рисунок 3.12 – Візуалізація результатів роботи моделі та попередження про пошкодження панелі

У нижній частині інтерфейсу виводиться блок аналітичних даних, що включає індикатор рівня впевненості моделі, значення ймовірності несправності, а також можливість автоматичного формування текстового діагностичного звіту. Такий підхід дозволяє оператору миттєво оцінити стан фотоелектричної установки та прийняти рішення щодо подальшого технічного огляду.

Інтерфейс користувача забезпечує цілісне та ефективне представлення результатів моніторингу, поєднуючи в собі простоту використання, наочність та функціональну завершеність. Завдяки використанню сучасних компонентів Streamlit та чіткому структуруванню інформації система дозволяє оперативно оцінювати стан фотоелектричних панелей, реагувати на критичні зміни й формувати повноцінні діагностичні звіти.

РОЗДІЛ 4.

ОХОРОНА ПРАЦІ ТА БЕЗПЕКА У НАДЗВИЧАЙНИХ СИТУАЦІЯХ

4.1. Аналіз умов праці під час розробки ІСППР

Розроблення інтелектуальної системи підтримки прийняття рішень моніторингу стану фотоелектричних установок передбачає виконання комплексу інженерних, програмно-аналітичних та експериментальних робіт, які проводяться в офісних або лабораторних умовах. Такі умови праці належать до категорії робіт із переважанням розумового навантаження та використанням сучасної комп'ютерної техніки. Основну частину часу розробник проводить за персональним комп'ютером, виконуючи програмування, тестування нейронних моделей, опрацювання графічних зображень та формування документації. Це потребує аналізу факторів, що впливають на безпеку та комфорт праці, зокрема мікрокліматичних параметрів, рівнів шуму, освітленості та електробезпеки.

У процесі роботи з комп'ютерною технікою головними шкідливими факторами є статичне навантаження на м'язи спини та шиї, підвищене напруження зору, можливе перевантаження психоемоційної сфери через тривалу концентрацію уваги, а також електромагнітні та теплові випромінювання, що утворюються компонентами ПК та периферійного обладнання. Окрім цього, у лабораторному середовищі, де виконуються експерименти з тестування продуктивності нейронних моделей, передбачено використання високонавантажених графічних процесорів, які можуть створювати додаткове тепловиділення. Тому важливим аспектом є забезпечення раціональної вентиляції та клімат-контролю.

Умови праці під час розроблення ІСППР характеризуються помірними рівнями небезпеки, проте їх недотримання може призвести до зниження працездатності персоналу, розвитку офтальмологічних та опорно-рухових розладів, підвищення втоми і стресу. Тому важливим заходом є впровадження

систематичного контролю параметрів робочого середовища та дотримання раціонального режиму праці й відпочинку.

4.2. Аналіз небезпечних і шкідливих виробничих чинників

Нижче наведено узагальнену схему чинників, що впливають на умови праці програмістів та інженерів під час створення ІСППР.



Рисунок 4.1 – Основні чинники, що впливають на умови праці під час розробки ІСППР

Схема узагальнює ключові фактори, які необхідно враховувати під час організації робочого місця для розробника. Відповідність вимогам охорони праці є критичною для забезпечення продуктивності та довготривалого комфортного функціонування персоналу.

Таблиця 4.1 узагальнює найважливіші параметри робочого середовища, які потребують контролю. Виконання цих вимог дозволяє знизити ризики професійного перевтомлення та покращити якість виконання інженерних завдань.

Таблиця 4.1 – Характеристика чинників виробничого середовища під час розроблення ІСППР

Чинник	Характеристика	Потенційний вплив	Вимоги та рекомендації
Освітленість	Природне та штучне світло	Погіршення зору, втома очей	300–500 лк, відсутність бликів на моніторі
Мікроклімат	Температура, вологість, циркуляція повітря	Неприємні відчуття, зниження працездатності	20–24°C, вологість 40–60%
Шум	Вентилятори ПК, устаткування	Дратівливість, стрес	≤ 50 дБ у робочій зоні
Електромагнітні поля	Монітори, блоки живлення, кабелі	Накопичений вплив	Відповідність ДСТУ EN 61000
Ергономіка	Положення монітора, стільця, клавіатури	Біль у спині, шії, зап'ястях	Настроювана висота столу, ортопедичне крісло
Психоемоційні чинники	Високе інтелектуальне навантаження	Втома, зниження концентрації	Перерви кожні 60 хв, режим Pomodoro

У процесі створення ІСППР значну увагу приділяють ергономічній організації робочого місця. Монітор повинен розташовуватися на відстані 50–70 см від очей з верхньою частиною екрану на рівні зору користувача. Стілець має забезпечувати підтримку поперекового відділу хребта, а стіл – мати достатню площу для розміщення обладнання таким чином, щоб уникнути надмірного нахилу корпусу. Додатково рекомендується використовувати фонове підсвічування, що зменшує контраст між екраном і навколишнім середовищем.

З погляду електробезпеки, робоче місце має відповідати вимогам щодо захисту від ураження електричним струмом, особливо при наявності потужних комп'ютерних систем або зовнішніх прискорювачів (GPU). Обов'язковими є використання заземлених розеток, справних кабелів живлення, автоматичних

вимикачів та справної вентиляції корпусів обладнання. Програмно-аналітичні роботи не передбачають контакту з високовольним устаткуванням, однак підвищена теплова генерація комп'ютерних систем потребує надійного охолодження та регулярного технічного огляду.

4.3. Безпека праці під час використання ІСППР

Експлуатація інтелектуальної системи підтримки прийняття рішень моніторингу стану фотоелектричних установок пов'язана з роботою операторів моніторингових центрів, інженерів-діагностів та технічного персоналу, який здійснює обробку, аналіз і документування результатів діагностики. Ця діяльність здійснюється у приміщеннях із використанням комп'ютерного обладнання та мережових систем, тому питання безпеки праці охоплюють комплекс організаційних, технічних та санітарно-гігієнічних вимог.

З огляду на специфіку ІСППР, основними факторами впливу є психоемоційне навантаження, зорове перевантаження, робота з великими обсягами інформації, використання мережевого обладнання та електронних засобів обробки даних. У процесі використання системи оператор повинен контролювати стан електричних мереж, коректність роботи інтерфейсу, а також вчасно реагувати на повідомлення про можливі пошкодження фотоелектричних панелей. Тому раціональна організація робочих місць та оптимізація інтерфейсу системи є важливими складовими безпечної праці.



Рисунок 4.3 – Основні напрями забезпечення безпеки праці під час використання ІСППР

Схема (рис. 4.3) демонструє основні напрями, які формують безпечне середовище під час роботи з системою. Надійність технічних елементів, комфортні умови для оператора та захищеність інформації мають однакове значення в загальній структурі безпеки.

У процесі використання ІСППР велике значення мають ергономічні параметри. Оператор повинен працювати у положенні, що не створює тривалої статичної напруги, а монітор має розташовуватися так, щоб уникати неприродного нахилу голови та перенапруження м'язів шиї. Рекомендована відстань до екрана становить 50–70 см. Зорове навантаження зменшується за рахунок використання якісного дисплея із частотою оновлення не менше 60 Гц, м'якого фоново-білого освітлення та застосування режимів зниження яскравості та синього спектра у вечірній час.

Під час тривалої роботи з аналітичними панелями ІСППР можливе виникнення психоемоційного навантаження, особливо у випадках, коли система автоматично повідомляє про критичні ризики чи пошкодження обладнання. Це створює додаткову відповідальність для оператора, тому важливим аспектом є регламентований режим праці й відпочинку. Згідно з санітарно-гігієнічними нормами, рекомендовано робити коротку перерву кожні 50–60 хвилин роботи за комп'ютером із виконанням вправ для очей і розвантаження шийно-плечового відділу.

Важливою складовою безпеки є електробезпека, оскільки система використовує високопродуктивне обладнання й мережеву інфраструктуру. Електричні розетки мають бути заземлені, а кабельні канали – правильно організовані для запобігання спотиканню та механічним пошкодженням. Блоки живлення серверних компонентів потребують регулярної перевірки на перегрів та відповідності стандартам електробезпеки. У разі встановлення системи в центрі моніторингу з підвищеним тепловиділенням від апаратури необхідно врахувати доступність внутрішньої вентиляції та захист від короткого замикання.

У сукупності всі ці заходи формують безпечне та контрольоване середовище для операторів, інженерів і технічних спеціалістів, які працюють з ІСППР. Грамотно організовані умови дозволяють не лише знизити ймовірність негативного впливу виробничих факторів, а й підвищити точність, надійність та оперативність прийняття рішень під час моніторингу фотоелектричних установок.

4.4. Захист населення під час надзвичайних ситуацій

Захист населення в умовах надзвичайних ситуацій базується на завчасному плануванні, оперативному реагуванні та інформуванні громадян про можливі загрози. У цьому процесі важливу роль відіграють системи моніторингу, що забезпечують своєчасне виявлення небезпечних подій, оповіщення та підтримку роботи аварійно-рятувальних служб. Під час загрози техногенного чи природного характеру населенню необхідно надати чіткі інструкції щодо евакуації, укриття та першочергових дій, спрямованих на збереження життя та здоров'я.

Дотримання вимог з цивільного захисту передбачає наявність систем оповіщення, працездатних укриттів, доступних маршрутів евакуації та забезпечення найбільш уразливих груп населення необхідними засобами підтримки. Важливо, щоб інформація про ризики була оперативною й достовірною, а дії органів місцевого самоврядування — узгодженими із службами ДСНС. Своєчасна координація між службами та населенням значно зменшує наслідки надзвичайних ситуацій та дає змогу мінімізувати людські втрати.

РОЗДІЛ 5.

ЕКОНОМІЧНА ЕФЕКТИВНІСТЬ ВІД ВИКОРИСТАННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ МОНІТОРИНГ СТАНУ ФОТОЕЛЕКТРИЧНИХ УСТАНОВОК

Економічна доцільність упровадження інтелектуальної системи моніторингу стану фотоелектричних установок ґрунтується на зіставленні витрат на її розроблення та експлуатацію з отриманими результатами у вигляді додаткових доходів та зменшення операційних витрат. Застосування ІСППР дає змогу своєчасно виявляти пошкоджені панелі, скорочувати тривалість простою, зменшувати втрати генерації електроенергії та оптимізувати витрати на регламентні огляди. У цьому розділі наведено методику оцінювання економічного ефекту, сформовано вихідні дані для розрахунків та продемонстровано приклад розрахунку для умовної фотоелектричної установки.

Для оцінювання ефективності використано показники річного економічного ефекту, терміну окупності та рівня рентабельності інвестицій. Загальний річний економічний ефект доцільно визначати як різницю між сумою додаткових доходів та зекономлених коштів і річними експлуатаційними витратами на підтримку функціонування системи. У загальному вигляді річний економічний ефект E_p можна записати так:

$$E_p = E_{ен} + E_{обс} - C_{екс}, \quad (5.1)$$

де $E_{ен}$ – додатковий дохід від зменшення втрат генерації електроенергії; $E_{обс}$ – економія на витратах обслуговування та діагностики; $C_{екс}$ – річні витрати на експлуатацію ІСППР.

Додатковий дохід від зменшення втрат генерації електроенергії формується за рахунок зменшення простоїв пошкоджених панелей та швидшого виявлення дефектів. Якщо позначити через Q річний обсяг виробництва електроенергії станцією, через p_1 початкову частку втрат до впровадження

системи, а через p_2 частку втрат після впровадження ІСППР, то обсяг додатково згенерованої енергії становитиме:

$$\Delta Q = Q \cdot (p_1 - p_2). \quad (5.2)$$

Додатковий річний дохід від зменшення втрат електроенергії обчислюється за формулою:

$$E_{en} = \Delta Q \cdot T_{тариф}, \quad (5.3)$$

де $T_{тариф}$ – середній тариф на електроенергію, грн/кВт·год.

Економія на витратах обслуговування пов'язана зі зменшенням кількості виїздів сервісних бригад та обсягів ручної діагностики. Якщо вихідні річні витрати на обслуговування становлять $C_{обсл}^{(0)}$, а після впровадження ІСППР вони скорочуються до $C_{обсл}^{(1)}$, тоді економія визначається як:

$$E_{обсл} = C_{обсл}^{(0)} - C_{обсл}^{(1)}. \quad (5.4)$$

Термін окупності проєкту $T_{ок}$ розраховується за класичною залежністю:

$$T_{ок} = \frac{I}{E_p}, \quad (5.5)$$

де I – сукупні інвестиції у створення та впровадження системи.

Для додаткової оцінки може бути використано показник рентабельності інвестицій:

$$R = \frac{E_p}{I} \cdot 100\%. \quad (5.6)$$

Для демонстрації практичного застосування описаної методики розглянемо умовний приклад. Нехай фотоелектрична установка має встановлену потужність 1 МВт, а її річний виробіток становить $Q = 1400 \text{ МВт} \cdot \text{год} = 1400000 \text{ кВт} \cdot \text{год}$. До впровадження інтелектуальної системи моніторингу орієнтовні втрати генерації через несвоєчасне виявлення пошкоджень становили $p_1 = 4\%$, після впровадження системи очікується їх зниження до $p_2 = 2\%$. У результаті обсяг додатково збереженої електроенергії становитиме:

$$\Delta Q = 1400000 \cdot (0,04 - 0,02) = 1400000 \cdot 0,02 = 28000 \text{ кВт год.}$$

Припустимо, що середній тариф на електроенергію для відповідної категорії споживача дорівнює $T_{\text{тариф}} = 5,0 \text{ грн / кВт} \cdot \text{год}$. Тоді додатковий річний дохід від зменшення втрат генерації становитиме:

$$E_{\text{ен}} = 28000 \cdot 5,0 = 140000 \text{ грн / рік.}$$

Паралельно з цим відбувається оптимізація витрат на сервісне обслуговування. Нехай до впровадження ІСППР проводилося 8 планових та позапланових виїздів сервісної бригади на рік із середньою вартістю одного виїзду 25000 грн, що дає:

$$C_{\text{обсл}}^{(0)} = 8 \cdot 25000 = 200000 \text{ грн / рік.}$$

За рахунок використання інтелектуальної системи моніторингу кількість виїздів скорочується до 4 на рік, отже:

$$C_{\text{обсл}}^{(1)} = 4 \cdot 25000 = 100000 \text{ грн / рік.}$$

Річна економія витрат на обслуговування дорівнює:

$$E_{\text{обсл}} = 200000 - 100000 = 100000 \text{ грн / рік.}$$

Припустимо, що річні експлуатаційні витрати на підтримку ІСППР, включно з ліцензійним програмним забезпеченням, хмарними сервісами та технічною підтримкою, становлять $C_{\text{екс}} = 40000 \text{ грн / рік}$. Тоді загальний річний економічний ефект від упровадження системи розраховується за формулою:

$$E_p = 140000 + 100000 - 40000 = 200000 \text{ грн / рік.}$$

Інвестиції у створення, налаштування та впровадження ІСППР для умовної електростанції оцінюються на рівні $I = 350000 \text{ грн}$. У цьому випадку розрахунковий термін окупності складе:

$$T_{\text{ок}} = \frac{350000}{200000} = 1,75 \text{ років.}$$

Рівень рентабельності інвестицій за рік можна оцінити як:

$$R = \frac{200000}{350000} \cdot 100\% \approx 57,1\%.$$

Узагальнені результати розрахунку економічного ефекту подано в таблиці 5.1, де відображено ключові показники, що характеризують доцільність впровадження інтелектуальної системи моніторингу стану фотоелектричних установок.

Таблиця 5.1 – Результати розрахунку економічної ефективності впровадження ІСППР

Показник	Одиниця виміру	Значення
Річний виробіток електроенергії	кВт·год	1 400 000
Частка втрат до впровадження системи	%	4
Частка втрат після впровадження системи	%	2
Додатково збережена енергія	кВт·год/рік	28000
Тариф на електроенергію	грн/кВт·год	5,0
Додатковий дохід від зменшення втрат генерації	грн/рік	140000
Витрати на обслуговування до впровадження	грн/рік	200000
Витрати на обслуговування після впровадження	грн/рік	100000
Економія на витратах обслуговування	грн/рік	100000
Річні витрати на експлуатацію ІСППР	грн/рік	40000
Загальний річний економічний ефект	грн/рік	200000
Інвестиції в ІСППР	грн	350000
Термін окупності	року	1,75
Орієнтовна річна рентабельність інвестицій	%	57,1

Проведені розрахунки підтверджують економічну доцільність впровадження інтелектуальної системи моніторингу: за рахунок зменшення втрат генерації та скорочення витрат на обслуговування річний економічний ефект становить близько 200 тис. грн, що забезпечує термін окупності 1,75 року та орієнтовну рентабельність інвестицій на рівні 57 %. Це дозволяє прогнозувати стабільний економічний приріст протягом усього строку експлуатації системи.

ВИСНОВКИ І ПРОПОЗИЦІЇ

Проведений аналіз підтвердив, що традиційні методи контролю технічного стану фотоелектричних установок не відповідають потребам сучасних високопродуктивних сонячних електростанцій. Інтелектуальні системи, побудовані на основі згорткових нейронних мереж і даних, отриманих безпілотними літальними апаратами, забезпечують суттєве підвищення точності та оперативності діагностики. Поєднання термографічних та візуальних зображень створює комплексний технологічний підхід, що дозволяє автоматично виявляти дефекти та мінімізувати втрати виробітку електроенергії.

Результати аналізу підтверджують доцільність розроблення та впровадження системи моніторингу на основі глибинного навчання. Запропонований підхід відповідає сучасним тенденціям цифровізації енергетики та має потенціал до масштабування й подальшого вдосконалення. Розширення навчальних наборів даних і оптимізація архітектури нейронних мереж здатні підвищити надійність і стійкість системи, що сприятиме зростанню ефективності роботи фотоелектричних станцій та розвитку відновлюваної енергетики в цілому.

Для побудови моделі моніторингу технічного стану фотоелектричних установок у роботі використано відкритий датасет Solar Panel Infrared Images, опублікований на платформі Roboflow Universe. Обраний датасет повністю відповідає задачам кваліфікаційної роботи та дає можливість сформувати якісну тренувальну вибірку для побудови моделі моніторингу стану фотоелектричних установок.

DataFrame легко інтегрується з бібліотеками TensorFlow та PyTorch, оскільки може бути перетворений у формат tf.data.Dataset, що значно прискорює процес батчування та подальшого навчання моделі [4]. Відтак, створення структурованого DataFrame є основним кроком, який визначає якість усіх наступних етапів моделювання та проєктування системи моніторингу фотоелектричних установок.

Запропонований алгоритм попереднього опрацювання даних дозволив забезпечити їх однорідність, їхню коректну подачу на вхід нейронної мережі та зменшити вплив шуму й варіацій освітлення. Кожен етап обробки є важливим компонентом підготовчої частини моделювання, оскільки згорткові мережі особливо чутливі до правильного нормування та розмірності зображення.

Стратифікований поділ вибірки, збереження балансу між класами, використання ефективного конвеєра даних і попередня візуальна перевірка структури наборів забезпечують надійну основу для подальшого навчання моделі моніторингу стану фотоелектричних панелей із використанням згорткової нейронної мережі.

Аналіз отриманих результатів показав, що найвищу точність та найкраще співвідношення між точністю і повнотою продемонстрували архітектури MobileNetV2 та ResNet50V2. При цьому MobileNetV2 виявилася помітно швидшою в навчанні, що робить її більш привабливою для практичних систем моніторингу, які можуть використовуватися в умовах обмежених обчислювальних ресурсів. Базова модель SimpleCNN та EfficientNetB0 продемонстрували приблизно однаковий рівень точності, який можна розглядати як відправну точку для порівняння. Результати цього етапу слугуватимуть основою для подальшого вибору найкращої архітектури згорткової нейронної мережі, що буде використана в інтегрованій системі моніторингу стану фотоелектричних установок.

Встановлено, що саме MobileNetV2 найповніше відповідає вимогам системи моніторингу технічного стану фотоелектричних установок. Її архітектура, оптимізована для мобільних і вбудованих застосувань, забезпечує високу точність класифікації при мінімальних обчислювальних витратах, а також стійкість до різноманітних особливостей термографічних зображень. Тому саме ця модель обрана як основа для подальшої інтеграції у розроблювану інтелектуальну систему моніторингу.

Завдяки відкритій архітектурі та модульній організації ІСППР може бути доповнена додатковими алгоритмами, включаючи сегментаційні моделі, системи

визначення локалізації дефектів та механізми прогнозування деградації панелей на основі тимчасових рядів.

Архітектура програмного комплексу створено таким чином, щоб забезпечити цілісність обробки зображень та стабільність під час роботи в умовах різного навантаження. Основою реалізації стала трирівнева модель побудови системи, де кожен рівень виконує окремий фрагмент логіки, але водночас залишається взаємопов'язаним з іншими через внутрішні API. Така структура дозволяє розгортати програмний комплекс як на локальній станції, так і на хмарній інфраструктурі без зміни фундаментальних механізмів взаємодії модулів.

Комплекс модулів збору, зберігання та обробки даних забезпечує послідовний і структурований потік інформації, на основі якого формуються аналітичні висновки щодо технічного стану фотоелектричних панелей. Така модульна організація дає змогу масштабувати систему, підключати нові джерела даних та оптимізувати алгоритмічні процедури глибинного аналізу.

Інтеграція результатів згорткової нейронної мережі у систему моніторингу перетворює процес діагностики фотоелектричних установок на автоматизований і повністю керований потоками даних. Такий підхід дозволяє істотно знизити час реагування на критичні зміни, підвищити точність аналізу та забезпечити сталість роботи системи навіть у разі обробки великих потоків зображень. Завдяки поєднанню глибинних моделей із модулем інтерфейсу та механізмом сповіщення система набуває властивостей повноцінного інтелектуального інструменту для технічного моніторингу.

Запропонований інтерфейс користувача забезпечує цілісне та ефективне представлення результатів моніторингу, поєднуючи в собі простоту використання, наочність та функціональну завершеність. Завдяки використанню сучасних компонентів Streamlit та чіткому структуруванню інформації система дозволяє оперативно оцінювати стан фотоелектричних панелей, реагувати на критичні зміни й формувати повноцінні діагностичні звіти.

Запропоновані заходи з охорони праці забезпечують створення безпечних умов для розробників і користувачів ІСППР, знижують технічні та організаційні ризики та гарантують надійне функціонування системи. Дотримання вимог електробезпеки, пожежної безпеки та інформаційного захисту формує необхідні передумови для стабільної експлуатації інтелектуальної системи на всіх етапах її розроблення та впровадження.

Проведені розрахунки підтверджують економічну доцільність впровадження інтелектуальної системи моніторингу: за рахунок зменшення втрат генерації та скорочення витрат на обслуговування річний економічний ефект становить близько 200 тис. грн, що забезпечує термін окупності 1,75 року та орієнтовну рентабельність інвестицій на рівні 57 %. Це дозволяє прогнозувати стабільний економічний приріст протягом усього строку експлуатації системи.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Боднарчук О.В., Андрієнко А.В. Методи та засоби побудови інтелектуальних інформаційних систем. Київ: КНУ ім. Тараса Шевченка, 2021. 312 с.
2. Бутирін, В. В., Клименко, В. Г., Шмаль, С. М. Відновлювана енергетика: сучасні технології та перспективи розвитку. Київ: Наукова думка, 2020. 356 с.
3. Гандзюк, М. П., Давиденко, В. М. Безпека життєдіяльності та охорона праці в інформаційних технологіях. Київ: КНЕУ, 2022. 228 с.
4. Горбенко, І. Д., Коваленко, В. О. Основи машинного навчання та інтелектуальних систем. Харків: ХНАМГ, 2021. 284 с.
5. Дяченко, С. О., Ткаченко, І. В. Фотогальванічні системи: проектування, експлуатація та технічний контроль. Одеса: ОНМУ, 2021. 296 с.
6. Жидецький В.Ц., Джигирей В.С., Мельников О.В. Основи охорони праці. Підручник. Вид. 5-е, доповнене. Львів: Афіша, 2012. 350с.
7. Класифікація в Python з Scikit-Learn та Pandas. URL: <https://stackabuse.com/classification-in-python-with-scikit-learn-and-pandas/> (дата звернення: 14.09.2025).
8. Кравець П.Ю., Кудінов Є.А. Інтелектуальні системи обробки інформації: теорія та практичні аспекти. Львів: Видавництво ЛНУ ім. І. Франка, 2020. 286 с.
9. Лехман С.Д., Рублев В.І., Рябцев Б.І. Запобігання аварійності і травматизму у сільському господарстві. К.: Урожай, 1993. 267 с.
10. Ситнік Б.Т. Основи інформаційних систем і технологій: навч. посіб. Харків: УкрДУЗТ, 2018. 130 с.
11. Стрілець, В. П., Кравець, О. М. Системи моніторингу та діагностики енергетичного обладнання: теорія і практика. Львів: ЛНУ «Львівська політехніка», 2019. 312 с.

12. Тимченко Л.І., Дорошенко А.О. Системи підтримки прийняття рішень: теорія та практичні рішення. Харків: НТУ «ХПІ», 2019. 274 с.
13. Тригуба А. М., Кондисюк І. В., Коваль Н. Я. Алгоритм прийняття управлінських рішень в умовах невизначеності із використанням машинного навчання. Вчені Львівського національного аграрного університету виробництву: каталог інноваційних розробок, Вип. 20, Львів: ЛНАУ, 2020, С. 39.
14. Тригуба А., Маланчук О., Тригуба І., Мармуляк А., Демчина В. Андрушків О., Олійник Р. Вплив сучасних інформаційних технологій на процеси ініціації та планування проєктів розвитку громад та регіонів. Вісник Львівського національного університету природокористування: агроінженерні дослідження. №24. Львів: Львів НУП, 2024. С. 123-130.
15. Тригуба А., Тригуба І., Фтома О., Кондисюк І., Коваль Н. Системний підхід до оцінення ризиків несвоєчасного виконання робіт в інтегрованих проєктах. Вісник Львівського національного аграрного університету: агроінженерні дослідження, № 23, Львів: ЛНАУ, 2019, С. 123-130.
16. Тригуба А., Тригуба І., Чубик Р., Кондисюк І., Коваль Н., Панюра Я. Прогнозування обсягів заготівлі сировини на території громад із використанням штучних нейронних мереж. Вісник Львівського національного аграрного університету: агроінженерні дослідження, № 24, Львів: ЛНАУ, 2020, С. 143-151.
17. Укргідрометцентр. Кліматичні дані України. Київ, 2023. URL: <https://uhmi.org.ua>
18. Ansari A. S., El Sayed H. M., Islam M. R. A review of monitoring technologies for solar photovoltaic systems // Sustainability. 2021. Vol. 13, No. 15. P. 1–20. DOI: 10.3390/su13158317
19. Bartler A., Mauch L., Bin Y., Reuter M. Automated Detection of Solar Cell Defects with Deep Learning // Proceedings of the 26th European Signal Processing Conference (EUSIPCO 2018). Rome, Italy, 2018. DOI: 10.23919/EUSIPCO.2018.8553025.
20. Bartler A., Mauch L., Bin Y., Reuter M. Automated Detection of Solar Cell Defects with Deep Learning // Proceedings of the 26th European Signal

Processing Conference (EUSIPCO 2018). Rome, Italy, 2018. DOI: 10.23919/EUSIPCO.2018.8553025

21. Circuit Digest. *IoT-Based Solar Power Monitoring System Using ESP8266*. 2024. URL: <https://circuitdigest.com>

22. Clean Energy Reviews. Most Efficient Solar Panels in 2024 Comparison Chart. 2024. URL: <https://www.cleanenergyreviews.info/blog/most-efficient-solar-panels>

23. Fortune Business Insights. Solar Power Market Size, Share & COVID-19 Impact Analysis, By Technology (PV, CSP) and Regional Forecast, 2024-2032. Pune : Fortune Business Insights, 2024. URL: <https://www.fortunebusinessinsights.com/industry-reports/solar-power-market-100764>

24. International Energy Agency. Renewables 2023: Analysis and forecast to 2028. Paris : IEA, 2023. URL: <https://www.iea.org/reports/renewables-2023>

25. Kalay M. Ş. Systematic review of the data acquisition and monitoring systems for PV systems // Solar Energy. 2022. Vol. 240. P. 70–89. DOI: 10.1016/j.solener.2022.06.019

26. Kumar R., Singh P., & Saraswat S. A comprehensive review on solar photovoltaics // Solar Energy Advances. 2025. Vol. 3. Article 100007. DOI: 10.1016/j.seadv.2025.100007

27. Maysun Solar. Infrared Thermal Imaging of Solar Modules. 2023. URL: <https://www.maysunsolar.com>

28. Morando L. et al. Thermal and Visual Tracking of Photovoltaic Plants for Autonomous UAV Inspection // Drones. 2022. 6(11), 347. DOI: 10.3390/drones6110347.

29. Morando L., Recchiuto C. T., Calla J., Scuteri P., Sgorbissa A. Thermal and Visual Tracking of Photovoltaic Plants for Autonomous UAV Inspection // Drones. 2022. Vol. 6, No. 11. Article 347. DOI: 10.3390/drones6110347.

30. Morando L., Recchiuto C. T., Calla J., Scuteri P., Sgorbissa A. Thermal and Visual Tracking of Photovoltaic Plants for Autonomous UAV Inspection // Drones. 2022. Vol. 6, No. 11. Article 347. DOI: 10.3390/drones6110347
31. Morando L., Recchiuto C.T., Calla J. *Thermal and visual tracking of photovoltaic plants for autonomous UAV inspection*. Drones, 2022.
32. Pruthviraj U., Kashyap Y., Baxevanaki E., Kosmopoulos P. *Solar Photovoltaic Hotspot Inspection Using UAV Thermal Images*. Remote Sensing, 2023.
33. Pruthviraj U., Kashyap Y., Baxevanaki E., Kosmopoulos P. Solar Photovoltaic Hotspot Inspection Using Unmanned Aerial Vehicle Thermal Images at a Solar Field in South India. – Remote Sensing, 2023, 15(7), 1914. DOI: 10.3390/rs15071914
34. Segovia Ramírez I., García Márquez F. P., Parra Chaparro J. Convolutional Neural Networks and Internet of Things for Fault Detection by Aerial Monitoring of Photovoltaic Solar Plants // Measurement. 2024. Vol. 234. Article 114861. DOI: 10.1016/j.measurement.2024.114861.
35. Segovia Ramírez I., García Márquez F. P., Parra Chaparro J. Convolutional Neural Networks and Internet of Things for Fault Detection by Aerial Monitoring of Photovoltaic Solar Plants // Measurement. 2024. Vol. 234. Article 114861. DOI: 10.1016/j.measurement.2024.114861
36. Segovia Ramírez I., García Márquez F. P., Parra Chaparro J. Convolutional Neural Networks and Internet of Things for Fault Detection by Aerial Monitoring of Photovoltaic Solar Plants. – Measurement, 2024, 234, 114861. DOI: 10.1016/j.measurement.2024.114861
37. Segovia Ramírez I., García Márquez F., Parra Chaparro J. *Convolutional neural networks and IoT for fault detection in photovoltaic plants*. Measurement, vol. 234, 2024.
38. Silveira Junior C. R., Rocha Sousa C. E., Fonseca Alves R. H. Automatic Fault Classification in Photovoltaic Modules Using Denoising Diffusion Probabilistic Model, Generative Adversarial Networks, and Convolutional Neural Networks // Energies. 2025. Vol. 18, No. 4. Article 776. – DOI: 10.3390/en18040776.

39. Sinovoltaics. Microcracks in Solar Cells – Detection with EL Imaging. 2023. URL: <https://sinovoltaics.com>
40. Solar Panel Infrared Images Dataset. Roboflow Universe. – URL: <https://universe.roboflow.com/solarpanelimages/solar-panel-infrared-images>
41. SolarPower Europe. Global Market Outlook for Solar Power 2024–2028. Brussels : SolarPower Europe, 2024. URL: <https://www.solarpowereurope.org/insights/reports/global-market-outlook-2024-2028>
42. Tryhuba A., Kondysiuk I., Tryhuba I., Koval N., Bojarchuk O. Justification of the configuration of the logistic delivery system of perishable agricultural products. 2nd International Conference on Agriculture, Technology, Engineering and Sciences (ICATES 2019), Lviv, 2019, P. 144.
43. Tryhuba A., Kondysiuk I., Tryhuba I., Lub P. Approach and Software for Risk Assessment of Stakeholders of Hybrid Projects of Transport Enterprise. CEUR Workshop Proceedings, 2022, vol.3295, pp. 86-96.
44. Tryhuba A., Koval N., Kondysiuk I., Tryhuba I. Planning the time of performance of works in hybrid projects. 3rd International Workshop on Modern Machine Learning Technologies and Data Science Workshop, MoMLLeT and DS 2021, CEUR Workshop Proceedings 2917, Lviv-Shatsk, 2021, pp. 196-206.
45. U.S. Department of Energy. Monitoring Platforms for Solar Photovoltaic Systems. Washington, DC : DOE, 2023. URL: <https://www.energy.gov>

ДОДАТКИ

Додаток А

Фрагмент коду ІСППР для моніторингу фотоелектричних установок

```
%%writefile app.py
import streamlit as st
import numpy as np
import tensorflow as tf
from PIL import Image

# =====
# ЗАГОЛОВОК ТА ІНТЕРФЕЙС
# =====
st.set_page_config(page_title="ІСППР: Моніторинг фотоелектричних установок",
                    layout="wide")

st.markdown("""
<h1 style='text-align:center; color:#0A4D68;'>
    ☀ Інтелектуальна система підтримки прийняття рішень<br>
    Моніторинг стану фотоелектричних установок
</h1>
""", unsafe_allow_html=True)

st.markdown("""
<style>
.stButton button {
    border-radius: 10px;
    border: 2px solid #0A4D68;
    background-color: #E3F2FD;
    color: #0A4D68;
    font-size: 18px;
    padding: 10px 20px;
}
.stButton button:hover {
    background-color: #BBDEFB;
    border-color: #01579B;
}
</style>
""", unsafe_allow_html=True)

# =====
# ЗАВАНТАЖЕННЯ МОДЕЛІ
# =====
@st.cache_resource
def load_model():
    model = tf.keras.models.load_model("ResNet50V2.keras")
    return model

model = load_model()

# =====
# ЗАВАНТАЖЕННЯ ЗОБРАЖЕННЯ
```

```
# =====
st.subheader("Завантаження зображення з дрона")

uploaded_file = st.file_uploader("Завантажте фото:", type=["jpg", "png", "jpeg"])

def prepare_image(img):
    img = img.resize((128, 128))
    img_array = np.array(img) / 255.0
    return np.expand_dims(img_array, axis=0)

if uploaded_file:
    image = Image.open(uploaded_file).convert("RGB")

    col1, col2 = st.columns(2)

    with col1:
        st.image(image, caption="Вхідне зображення", use_column_width=True)

    with col2:
        st.info("Натисніть кнопку нижче для аналізу")

    if st.button("Проаналізувати стан"):
        img_batch = prepare_image(image)
        prediction = model.predict(img_batch)[0][0]

        if prediction > 0.5:
            result = "Виявлено можливе пошкодження панелі"
            color = "red"
        else:
            result = "Стан фотоелектричної установки: НОРМА"
            color = "green"

        st.markdown(
            f"<h2 style='color:{color}; text-align:center;'>{result}</h2>",
            unsafe_allow_html=True
        )

    # Додатковий графічний блок
    st.subheader("Аналітичні дані моделі")
    st.progress(float(prediction))

    col1, col2 = st.columns(2)
    with col1:
        st.metric("Ймовірність несправності", f"{prediction:.3f}")
    with col2:
        st.metric("Ймовірність норми", f"{1 - prediction:.3f}")

    # Збереження результату
    st.download_button(
        "Завантажити звіт",
        data=f"Результат аналізу: {result}\nЙмовірність: {prediction:.3f}",
        file_name="diagnostic_report.txt"
```

)

"Надіслати" (імітована функція)

st.success("Результат відправлено оператору моніторингової станції")