

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ**  
**Західноукраїнський національний університет**  
**Факультет комп'ютерних інформаційних технологій**  
Кафедра інформаційно-обчислювальних систем і управління

**ОЛЕКСЮК Дмитро Васильович**

**Методи визначення дефектів вітрових турбін на основі  
адаптивної нейронечіткої системи логічного висновку /**  
**Methods for Determining Wind Turbines Defects Using the**  
**Adaptive Neurofuzzy Inference System**

спеціальність: 122 - Комп'ютерні науки  
освітньо-професійна програма - Комп'ютерні науки

Кваліфікаційна робота

Виконав студент групи КНм-21  
Д. В. Олексюк

---

Науковий керівник:  
д.т.н., професор А.О. Саченко

---

Кваліфікаційну роботу  
допущено до захисту:

«\_\_\_» \_\_\_\_\_ 20\_\_\_ р.

В.о. завідувача кафедри

\_\_\_\_\_ Н.В. Дзюбановська

**ТЕРНОПІЛЬ - 2025**

**Факультет комп'ютерних інформаційних технологій**  
Кафедра інформаційно-обчислювальних систем і управління  
Освітній ступінь «магістр»  
спеціальність: 122 – Комп'ютерні науки  
освітньо-професійна програма – Комп'ютерні науки

ЗАТВЕРДЖУЮ  
В.о. завідувача кафедри  
\_\_\_\_\_ Н.М. Васильків  
« \_\_\_\_\_ » \_\_\_\_\_ 20\_\_ р.

**ЗАВДАННЯ**  
**НА КВАЛІФІКАЦІЙНУ РОБОТУ СТУДЕНТУ**  
**ОЛЕКСІУК Дмитро Васильович**

(прізвище, ім'я, по батькові)

1. Тема кваліфікаційної роботи **Методи визначення дефектів вітрових турбін на основі адаптивної нейронечіткої системи логічного висновку / Methods for Determining Wind Turbines Defects Using the Adaptive Neurofuzzy Inference System** керівник роботи д.т.н., професор А.О. Саченко  
затверджені наказом по університету від 20 грудня 2024 року № 938.

2. Строк подання студентом закінченої кваліфікаційної роботи 1 грудня 2025 р.

3. Вихідні дані до кваліфікаційної роботи: завдання на кваліфікаційну роботу студента, наукові статті, технічна література.

4. Основні питання, які потрібно розробити

- огляд предметної області та аналіз дефектів лопатей вітрових турбін;
- аналіз методів і алгоритмів автоматизованого виявлення дефектів на основі комп'ютерного зору та машинного навчання;
- аналіз нейронних мереж і методів нечіткої логіки для задач технічної діагностики;
- постановка задачі дослідження та формалізація вимог до системи діагностики;
- дослідження принципів побудови адаптивної нейронечіткої системи логічного висновку (ANFIS);
- розроблення методу визначення дефектів лопатей вітрових турбін із використанням ANFIS;
- дослідження засобів програмної реалізації запропонованого методу;
- реалізація програмного забезпечення та аналіз результатів експериментальних досліджень.

5. Перелік графічного матеріалу у роботі

- структурна схема запропонованого методу визначення дефектів лопатей вітрових турбін;
- архітектурна схема адаптивної нейронечіткої системи логічного висновку (ANFIS);
- графіки результатів експериментальних досліджень та порівняння з існуючими методами.

6. Консультанти розділів кваліфікаційної роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		Завдання видав	Завдання прийняв

7. Дата видачі завдання 20 грудня 2024 р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів кваліфікаційної роботи	Примітка
1	Затвердження теми кваліфікаційної роботи, ознайомлення з літературними джерелами та складання плану роботи.	до 01.01. 2025 р.	
2	Написання 1 розділу кваліфікаційної роботи	до 01.03. 2025 р.	
3	Написання 2 розділу кваліфікаційної роботи	до 20.05.2025 р.	
4	Написання 3 розділу кваліфікаційної роботи	до 28.10. 2025 р.	
5	Представлення попереднього варіанту кваліфікаційної роботи, перевірка та внесення змін керівником	до 11.11.2025 р.	
6	Опрацювання зауважень та представлення завершеного варіанту кваліфікаційної роботи. Підготовка супроводжуючих документів.	до 25.11.2025 р.	
7	Перевірка кваліфікаційної роботи на оригінальність тексту.	до 1.12.2025 р.	
8	Оформлення кваліфікаційної роботи та отримання допуску до захисту	до 04.12.2025 р.	
9	Подання кваліфікаційної роботи до захисту на засіданні атестаційної комісії.	до 14.12. 2025 р.	

Студент \_\_\_\_\_ Д.В. Олексюк  
підпис

Керівник роботи \_\_\_\_\_ д.т.н., професор А.О. Саченко  
підпис

## РЕЗЮМЕ

Кваліфікаційна робота на тему «Методи визначення дефектів вітрових турбін на основі адаптивної нейронечіткої системи логічного висновку» на здобуття освітнього ступеня «Магістр» зі спеціальності 122 «Комп'ютерні науки», освітньої програми «Комп'ютерні науки», виконана обсягом 86 сторінок та містить 16 рисунків, 6 таблиці, 4 додатки та список 41 використаних джерел.

Метою даної кваліфікаційної роботи є розробка методу визначення дефектів лопатей вітрових турбін на основі адаптивної нейронечіткої системи логічного висновку, який забезпечує підвищену точність, інтерпретованість результатів та зменшену обчислювальну складність порівняно з традиційними підходами.

Методи дослідження: методи комп'ютерного зору, теорія нечітких множин і нечіткої логіки, адаптивні нейронечіткі системи (ANFIS), методи машинного та глибинного навчання, цифрова обробка зображень, статистичний аналіз та методи оцінювання точності моделей.

Результати дослідження: розроблено інтегрований метод діагностики дефектів лопатей вітрових турбін, який поєднує автоматичне виявлення дефектів за допомогою моделей комп'ютерного зору та їх інтерпретацію через адаптивну нейронечітку систему логічного висновку. Запропонований підхід дозволяє оцінювати не лише наявність дефекту, але й рівень його критичності відповідно до стандартів ІЕС 61400, забезпечуючи прозорість та пояснюваність прийнятих рішень.

Практичне значення одержаних результатів полягає у можливості використання розробленого методу в системах моніторингу стану вітрових турбін, програмному забезпеченні для UAV-інспекцій та системах технічного обслуговування за станом, що сприяє зменшенню експлуатаційних витрат і підвищенню надійності вітроенергетичних установок.

Ключові слова: ВІТРОВА ТУРБІНА, ДЕФЕКТИ ЛОПАТЕЙ, ANFIS, НЕЧІТКА ЛОГІКА, КОМП'ЮТЕРНИЙ ЗІР, UAV, КРИТИЧНІСТЬ ДЕФЕКТІВ.

## ABSTRACT

The qualification work on the topic " Methods for Determining Wind Turbines Defects Using the Adaptive Neurofuzzy Inference System " for obtaining the educational degree "Master" in specialty 122 "Computer Science", educational program "Computer Science", is 86 pages long and contains 16 figures, 6 tables, 4 appendices and a 41 list of sources used.

The purpose of this qualification work is to develop a method for determining wind turbine blade defects based on an adaptive neurofuzzy logical inference system, which provides increased accuracy, interpretability of results and reduced computational complexity compared to traditional approaches.

Research methods: computer vision methods, fuzzy set theory and fuzzy logic, adaptive neurofuzzy systems (ANFIS), machine and deep learning methods, digital image processing, statistical analysis and methods for assessing the accuracy of models.

Research results: an integrated method for diagnosing defects in wind turbine blades has been developed, which combines automatic defect detection using computer vision models and their interpretation through an adaptive neurofuzzy inference system. The proposed approach allows assessing not only the presence of a defect, but also the level of its criticality in accordance with IEC 61400 standards, ensuring transparency and explainability of decisions made.

The practical significance of the results obtained lies in the possibility of using the developed method in wind turbine condition monitoring systems, software for UAV inspections and condition-based maintenance systems, which contributes to reducing operating costs and increasing the reliability of wind power plants.

Keywords: WIND TURBINE, BLADE DEFECTS, ANFIS, FUZZY LOGIC, COMPUTER VISION, UAV, DEFECT CRITICALITY.

## ЗМІСТ

Перелік умовних позначень.....	7
Вступ .....	8
1 Теоретичні засади діагностики дефектів вітрових турбін.....	12
1.1 Аналіз предметної області .....	12
1.2 Аналіз методів та підходів до визначення дефектів вітрових турбін.....	16
1.3 Постановка задачі дослідження .....	19
Висновки до розділу 1.....	20
2 Розробка методу визначення дефектів на основі ANFIS.....	21
2.1 Концепція застосування адаптивної нейронечіткої системи логічного висновку.....	21
2.2 Архітектура ANFIS для визначення дефектів вітрових турбін.....	27
2.3 Розроблений метод визначення дефектів на основі ANFIS.....	31
Висновки до розділу 2.....	42
3 Реалізація методу та експериментальні дослідження.....	43
3.1 Програмні засоби та середовище реалізації.....	43
3.2 Реалізація екстракції ознак та навчання моделі.....	45
3.3 Результати експериментальних досліджень.....	54
3.4 Програмно-апаратна імплементація.....	60
Висновки до розділу 3.....	66
Висновки .....	67
Список використаних джерел .....	69
Додаток А Копії публікації.....	74
Додаток Б Схема диференціації критичності.....	78
Додаток В Параметри моделей та гіперпараметри навчання.....	79
Додаток Г Фрагменти програмної реалізації запропонованого методу.....	80

## ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

ANFIS — Adaptive Neuro-Fuzzy Inference System (адаптивна нейронечітка система логічного висновку)

UAV — Unmanned Aerial Vehicle (безпілотний літальний апарат)

CNN — Convolutional Neural Network (згорткова нейронна мережа)

YOLO — You Only Look Once (модель детекції об'єктів у реальному часі)

RGB — Red, Green, Blue (колірна модель)

IR — Infrared (інфрачервоний спектр)

ROI — Region of Interest (область інтересу)

FIS — Fuzzy Inference System (система нечіткого логічного висновку)

IEC — International Electrotechnical Commission (Міжнародна електротехнічна комісія)

CBM — Condition-Based Maintenance (технічне обслуговування за станом)

mAP — mean Average Precision (середня точність)

IoU — Intersection over Union (міра перекриття областей)

## ВСТУП

Стрімкий розвиток відновлюваної енергетики зумовлює різке зростання встановленої потужності вітрових електростанцій у світі. За даними міжнародних енергетичних звітів, темп щорічного збільшення вітрових потужностей нині перевищує попередні двадцятирічні показники, а частка вітроенергетики у загальному балансі “зеленої” генерації демонструє стабільне зростання. Проте разом зі збільшенням кількості турбін зростає і критичність проблеми експлуатаційної надійності, оскільки відмова окремого компонента віротурбіни може призвести до значних матеріальних збитків, падіння рівня генерації та необхідності проведення дорогих ремонтних робіт.

Одним із найбільш вразливих вузлів сучасної вітрової турбіни є лопаті, на які припадає основне аеродинамічне навантаження. Ерозія кромek, тріщини, деламінація, внутрішні перегріву, порушення цілісності композитної структури — усі ці дефекти виникають під дією змінних вітрових полів, ультрафіолетового випромінювання, ударного навантаження та циклічних механічних коливань. Оперативне визначення таких дефектів є пріоритетним завданням для стабільної роботи ВЕС, проте класичні методи контролю (візуальна інспекція, ультразвуковий контроль, термографія, віброаналіз) мають суттєві обмеження, пов’язані з необхідністю зупинки турбіни, небезпечністю виконання робіт на висоті або недостатньою точністю і швидкістю обробки сигналів.

Сучасні підходи до автоматизованої діагностики дедалі частіше базуються на використанні безпілотних літальних апаратів (UAV), мультиспектральної зйомки та глибоких нейронних мереж для первинного виявлення пошкоджень. Популярні моделі, такі як YOLOv8, U-Net, EfficientDet, демонструють високу точність під час виявлення області дефекту, але мають і низку недоліків — залежність від обчислювальних ресурсів, складність налаштування, недостатню інтерпретованість, а також обмеження щодо роботи в реальному часі.

У той же час існує потреба не лише у виявленні дефектів, але й у визначенні їхнього типу, ступеня небезпечності, критичності та прогнозуванні

можливих наслідків. Саме на цьому етапі класичні нейронні мережі демонструють недостатню прозорість і пояснюваність. Натомість адаптивні нейро-нечіткі системи логічного висновку (ANFIS) поєднують у собі здатність до навчання, притаманну нейронним мережам, та інтерпретованість нечіткої логіки.

Дослідження, присвячені ANFIS для вітроенергетики, показують, що такі системи здатні ефективно моделювати нелінійні залежності між вхідними параметрами турбіни та станом її компонентів, забезпечуючи підвищену точність, стійкість до шумів і можливість роботи зі змішаними даними (RGB, термографія, вібросигнали, спектральні характеристики). Крім того, адаптивні нейро-нечіткі моделі дозволяють зменшити кількість правил логічного висновку, оптимізувати обчислювальну складність і підвищити швидкість ухвалення рішень, що є критично важливим для систем оперативної діагностики.

Зважаючи на викладене, застосування адаптивної нейронечіткої системи логічного висновку є доцільним для задачі визначення дефектів лопатей вітрових турбін, особливо в умовах обмежених обчислювальних ресурсів та необхідності інтерпретованого пояснення результатів.

Мета роботи: розробити метод визначення дефектів вітрових турбін на основі адаптивної нейронечіткої системи логічного висновку (ANFIS), що забезпечує підвищену точність, інтерпретованість та зменшення обчислювальної складності порівняно з традиційними методами.

Для досягнення поставленої мети необхідно виконати такі завдання:

1. Проаналізувати предметну область та класифікувати типові дефекти лопатей вітрових турбін.
2. Дослідити сучасні методи діагностики та оцінити їхні переваги й недоліки.
3. Розробити метод визначення дефектів на основі ANFIS.
4. Сформулювати структуру нечіткої системи, набір лінгвістичних змінних і функцій належності.
5. Розробити алгоритм логічного висновку та навчання ANFIS.

6. Реалізувати програмний модуль для опрацювання даних UAV і генерації вхідних параметрів ANFIS.

7. Провести експериментальні дослідження та оцінити точність запропонованого методу.

8. Порівняти результати з існуючими підходами та сформулювати висновки щодо ефективності.

Об'єкт дослідження: система діагностики стану лопатей вітрових турбін.

Предмет дослідження: метод і модель визначення дефектів на основі адаптивної нейронечіткої системи логічного висновку.

У роботі застосовано:

- нечітку логіку та теорію нечітких множин;
- методи машинного навчання;
- адаптивні нейро-нечіткі системи (ANFIS);
- глибинні моделі комп'ютерного зору (YOLO, U-Net);
- цифрову обробку зображень;
- статистичний аналіз і методи оцінювання точності.

Наукова новизна: Розроблено вдосконалений метод визначення дефектів вітрових турбін на основі ANFIS, що використовує оптимізовану структуру правил і знижує обчислювальну складність.

Запропоновано модель, яка синтезує результати детекторів глибинного навчання з нечітким логічним висновком, забезпечуючи інтерпретованість результатів.

Показано можливість підвищення точності визначення дефектів порівняно з класичними підходами[1,2].

Отримані результати можуть бути використані:

- у системах моніторингу стану віротурбін;
- у програмному забезпеченні для UAV-інспекцій;
- у системах технічного обслуговування за станом (CBM);
- для зменшення витрат на обслуговування та підвищення надійності генерації.

Апробація роботи: Основні результати дослідження були представлені на III Всеукраїнській науково-практичній конференції студентів, аспірантів та молодих вчених «Інтелектуальні комп'ютерні системи та мережі» (додаток А).

# 1 ТЕОРЕТИЧНІ ЗАСАДИ ДІАГНОСТИКИ ДЕФЕКТІВ ВІТРОВИХ ТУРБІН

## 1.1 Аналіз предметної області

Вітроенергетика є однією з найбільш динамічно зростаючих галузей відновлюваної енергетики. За даними провідних аналітичних агентств та енергетичних спостережень, щорічні темпи встановлення нових вітроенергетичних потужностей демонструють стабільне зростання, що обумовлено світовим переходом до декарбонізації та необхідністю зниження енергетичної залежності держав від викопного палива. Вітрові турбіни сучасного покоління характеризуються високими коефіцієнтами корисної дії, здатністю працювати при низьких швидкостях вітру та можливістю встановлення як на суші, так і на морських платформах, що суттєво розширює їх потенціал застосування.

Разом із тим зростає і навантаження на системи експлуатаційної діагностики. Вітрові турбіни за своєю природою є складними механо-електричними об'єктами з нелінійними характеристиками та багато параметричною динамікою. Ключові компоненти — лопаті, редуктор, підшипники, генератор, електронні модулі керування — працюють у високонавантажених умовах, що робить надійність системи критично важливою для економічної ефективності всієї станції.

Лопаті вітрових турбін — складні композитні конструкції, що зазнають аеродинамічних, механічних і теплових навантажень. За даними [2], найпоширенішими видами ушкоджень є:

- ерозія кромки лопаті (leading-edge erosion);
- тріщини різної глибини та конфігурації;
- деламінація композитних слоїв;
- місцеві перегриви та термічні аномалії;
- ударні пошкодження та мікроструктурні дефекти.

Зазначені дефекти безпосередньо впливають на аеродинамічну ефективність лопатей, знижуючи коефіцієнт підйомної сили та потужності. У гіршому випадку це призводить до аварійних ситуацій, втрати елементів конструкції та довготривалої зупинки турбіни.

Згідно з аналізом у [1], навіть незначні дефекти на ранній стадії можуть бути структурно критичними через композитну природу матеріалу, де пошкодження часто прогресують нелінійно.

Класифікація дефектів лопатей на основі зібраних у наукових дослідженнях даних дефекти лопатей вітротурбін поділяють на кілька груп:

#### 1. Поверхневі дефекти:

- тріщини фарбового покриття;
- ерозія кромки;
- локальні вибоїни;
- поверхнєве стирання;
- сліди ударів дрібних предметів.

#### 2. Структурні дефекти:

- внутрішні тріщини;
- порушення цілісності композитних шарів;
- деламінація;
- деградація композиту під тепловим впливом.

#### 3. Термічні аномалії:

- перегрів через тертя;
- внутрішнє теплове розшарування;
- дефекти у зонах кріплення.

#### 4. Аеродинамічні дефекти:

- деформації профілю лопаті;
- відшарування сегментів поверхні;
- дефекти, що змінюють геометрію.

Усі ці категорії мають різний вплив на роботу турбіни, однак їх спільною рисою є те, що кризові дефекти неможливо визначити лише простим візуальним оглядом, що підтверджує необхідність сучасних інтелектуальних систем аналізу.

Сучасні методи діагностики у наукових роботах, присвячених експлуатації вітрових турбін, виділяють декілька основних методів виявлення дефектів:

1. Акустична емісія;

Дозволяє фіксувати мікросигнали, що виникають під час розвитку тріщин та внутрішніх деформацій. Ефективна на ранніх етапах, але потребує дорогого обладнання і складної інтерпретації.

2. Ультразвуковий контроль;

Ефективний для вимірювання глибини та локалізації дефектів, але потребує:

- зупинки турбіни;
- фізичного доступу до лопатей;
- участі фахівців високої кваліфікації.

3. Віброаналіз;

Застосовується переважно для діагностики редукторів і підшипників; непрямо може вказувати на дефекти лопатей, але не дає чіткої структурної інформації.

4. Інфрачервона термографія;

Сучасні дослідження, демонструють ефективність термальних камер у виявленні:

- підповерхневих дефектів,
- перегріву матеріалу,
- деламінації.

Термальні аномалії часто є першою ознакою складних дефектів.

5. Методи машинного зору.

Завдяки розвитку UAV та потужних моделей глибинного навчання (YOLO, U-Net, Mask R-CNN), візуальна інспекція отримала новий рівень автоматизації.

Використання мультиспектральних камер, що значно підвищує точність визначення критичності ушкоджень.

Попри розвиток методів діагностики, існуючі системи мають значні недоліки:

1. Висока обчислювальна складність при використанні CNN.
2. Неможливість оперативної роботи в польових умовах (мобільні платформи, обмежені процесори).
3. Нестача інтерпретованості рішень — типова проблема “black box AI”.
4. Потреба у великому масиві навчальних даних, що у випадку з рідкісними дефектами є складним завданням.
5. Неврахування рівня критичності дефектів, що фактично обмежує систему лише “детекцією”, а не прийняттям рішень.

Таким чином, у предметній області існує чіткий запит на:

- об’єднання методів машинного зору та інтелектуального логічного висновку;
- створення системи класифікації та оцінювання критичності дефектів;
- підвищення швидкодії та інтерпретованості.

Адаптивні нейро-нечіткі системи ANFIS у діагностиці турбін, що працюють показано успішне моделювання:

- нелінійні залежності між параметрами дефектів;
- взаємозв’язки між фотометричними та термальними ознаками;
- рівень критичності структурного пошкодження.

ANFIS як модель поєднує:

- адаптивність нейронної мережі,
- інтерпретованість нечіткої логіки,
- можливість роботи зі змішаними даними різної природи.

Це робить ANFIS оптимальним інструментом для задачі діагностики дефектів лопатей вітрових турбін.

## 1.2 Аналіз методів та підходів до визначення дефектів вітрових турбін

Сучасні системи діагностики вітрових турбін перебувають на перетині кількох наукових напрямів — композитних матеріалів, аеродинаміки, мехатроніки, комп'ютерного зору та інтелектуальних систем керування. Пошкодження лопатей, редуктора, підшипників або електронних вузлів можуть мати різну природу, а тому потребують різноманітних підходів до виявлення та інтерпретації. У світлі швидкого зростання кількості вітрових електростанцій критично важливим стає розвиток методів, здатних виявляти дефекти на ранніх стадіях, забезпечувати високу точність оцінки та працювати у режимі псевдо реального часу.

Першими методами, які почали застосовувати у практиці технічного обслуговування, стали традиційні підходи неруйнівного контролю — акустична емісія, ультразвукові дослідження, термографія та вібраційний аналіз. Акустична емісія дозволяє виявляти характерні імпульси, що виникають у матеріалі під впливом навантаження, особливо під час зародження мікротріщин. Попри високу чутливість, цей метод вимагає складного обладнання та ретельної фільтрації сигналів унаслідок значних завад. Ультразвукові технології добре підходять для локалізації внутрішніх дефектів та визначення їх глибини, однак вони потребують фізичного доступу до поверхні лопаті, що робить їх менш придатними для регулярного моніторингу у польових умовах.

Термографія, яка активно описується у роботах останніх років, зокрема в дослідженні [3], стала одним із ключових напрямів у виявленні дефектів композитних конструкцій. Теплові аномалії, які виникають у місцях внутрішніх тріщин чи деламінацій, дозволяють визначити пошкодження, що не проявляються на поверхні. Проте якість термографічного аналізу сильно залежить від умов навколишнього середовища, температурного градієнта та відстані до об'єкта, що потребує додаткових етапів нормалізації даних.

Інший класичний підхід — вібраційна діагностика — активніше використовується для аналізу стану механічних компонентів, таких як редуктори

й підшипники, але у випадку лопатей надає лише непрямі ознаки про можливі порушення їхньої роботи. Наявність незбалансованості, зміни жорсткості або аеродинамічних порушень можуть бути зафіксовані, однак інтерпретація таких сигналів є складною і вимагає використання додаткових методів аналізу.

З розвитком безпілотних літальних апаратів (UAV) почалося активне впровадження методів дистанційної діагностики, що відкрили можливість швидкого та безпечного огляду великої кількості турбін без необхідності їх зупинки. У дослідженнях [4] використання UAV стало основою для побудови системи збору фотознімків та відеоматеріалів, які обробляються нейронними мережами для автоматичного виявлення пошкоджень. Цей підхід значно підвищив продуктивність інспекцій, проте ускладнив задачу опрацювання великих обсягів даних та підвищив вимоги до обчислювальної потужності.

Найбільший прорив у сфері діагностики вітрових турбін пов'язаний із застосуванням глибинних нейронних мереж для обробки зображень. Моделі класу YOLO, EfficientDet, U-Net та їх модифікації дозволили виконувати сегментацію, локалізацію та класифікацію поверхневих дефектів із високою точністю. У роботі [5] використано YOLO для отримання векторів ознак, які далі передаються у нейро-нечітку систему, а у [6] запропоновано розширену систему на основі мультиспектральних даних RGB та термальних каналів, що дозволило підвищити точність визначення критичності дефектів. Такі методи дали можливість обробляти десятки тисяч знімків за короткий час і значно автоматизували процес моніторингу.

Попри це, глибинні нейронні мережі залишаються “чорними скриньками” у багатьох аспектах. Хоча вони демонструють високу точність, пояснюваність їхніх рішень залишається низькою, що є критично важливим у контексті промислової експлуатації. Крім того, такі моделі потребують значних обчислювальних ресурсів, а їхнє навчання може тривати від кількох годин до кількох днів, залежно від обсягу даних та конфігурації мережі.

Тому дослідники почали активно звертатися до поєднання глибинних моделей із системами нечіткого логічного висновку, що дозволяють

компенсувати нестачу інтерпретованості. У роботах з ANFIS, зокрема в [7, 8], акцент зроблено на можливості побудувати модель, яка не лише навчиться на прикладах, а й зможе пояснити свої рішення мовою правил. Така модель поєднує нечітку логіку, яка здатна працювати з невизначеними, частково достовірними або нечіткими даними, та нейронні мережі, що забезпечують адаптивність за рахунок навчання параметрів функцій належності.

Особливої уваги заслуговує питання критичності дефектів, яке тривалий час залишалося поза межами автоматизованих систем. Дослідження [9] показали, що класифікація за наявністю дефекту не є достатньою — інженерів цікавить рівень небезпеки, ймовірність прогресування та можливі наслідки. У статті запропоновано багаторівневу систему логічних правил, побудованих відповідно до норм ІЕС 61400, що дозволяє переходити від простої детекції до інженерної оцінки стану матеріалу. Це підтверджує необхідність створення системи, яка могла б інтерпретувати інформацію на рівні, зрозумілому фахівцям.

Поступово стало очевидним, що найефективнішим є підхід, який синтезує різні методи в єдину багаторівневу інтелектуальну систему. Використання UAV забезпечує збирання даних, глибинні нейронні мережі виконують детекцію дефектів, а ANFIS дає змогу інтерпретувати їх критичність на основі правил та нечітких змінних. Такий підхід не лише покращує точність, але й забезпечує прозорість ухвалення рішень та можливість використання системи в реальних умовах, навіть за обмежених обчислювальних ресурсів.

У сукупності огляд сучасних методів свідчить про те, що предметна область діагностики вітрових турбін є складною, багатовимірною та потребує інтелектуальних систем, здатних поєднувати машинне навчання, нечітку логіку та фізичні закономірності. Саме тому застосування адаптивної нейронечіткої системи логічного висновку видається найбільш перспективним і відповідає актуальним тенденціям у дослідженнях галузі

### 1.3 Постановка задачі дослідження

На підставі проведеного аналізу предметної області, сучасних методів діагностики та технологій обробки даних можна стверджувати, що задача визначення дефектів лопатей вітрових турбін є багатокomпонентною та потребує поєднання методів комп'ютерного зору, інтелектуальних систем логічного висновку та статистичної обробки сигналів. Проблематика ускладнюється тим, що дефекти композитних матеріалів часто мають нерегулярну структуру, невизначену природу та тенденцію до прогресування, яка не завжди корелює з їх початковими проявами.

У межах задачі оцінювання технічного стану турбіни важливо враховувати не лише факт наявності дефекту, але й його тип, масштаб, глибину, термічну активність, а також вплив на аеродинамічні характеристики конструкції. Базові методи комп'ютерного зору, які успішно локалізують пошкодження (YOLO, U-Net), працюють як інструменти первинного рівня — вони ідентифікують об'єкт, але не дають інженерної інтерпретації його критичності. Натомість стандарти галузі (IEC 61400) наголошують на необхідності інтегрованої оцінки небезпечності дефектів, що дозволяє визначати терміновість ремонту та ризики подальшої експлуатації.

З огляду на це, у роботі формулюється завдання створення інтелектуального методу, який поєднує інструменти автоматичної детекції зображень із системою інтерпретації на основі нечіткої логіки. На відміну від класичних нейронних мереж, які функціонують як «чорна скринька», метод ANFIS дає змогу пояснити рішення у вигляді набору правил і нечітких змінних. Це особливо важливо у сфері енергетики, де результати автоматичної діагностики повинні бути зрозумілими для експертів, інженерів та сервісних фахівців.

Таким чином, основна задача, сформульована в роботі, полягає у створенні адаптивної нейронечіткої системи логічного висновку, яка здатна:

- приймати на вхід ознаки дефектів, виявлені моделями комп'ютерного зору;
- інтерпретувати ці ознаки у термінах лінгвістичних змінних (ступінь пошкодження, розмір, інтенсивність теплового сигналу, контрастність, глибина);
- виконувати логічний висновок та давати оцінку рівня критичності;
- працювати за обмежених обчислювальних ресурсів і бути придатною для інтеграції у системи моніторингу UAV.

Побудова такої системи потребує:

- виділення ознак з RGB та термальних зображень;
- формування компактного набору функцій належності та правил;
- адаптації параметрів ANFIS методом навчання;
- проведення експериментальних досліджень для оцінки точності моделі.

Очікуваним результатом є система, здатна забезпечити збалансовану комбінацію точності, інтерпретованості та обчислювальної ефективності, що підтверджено у працях [10, 11].

## Висновки до розділу 1

1. Проаналізовано предметну область діагностики дефектів лопатей вітрових турбін, визначено їх конструктивні особливості та основні типи пошкоджень, що виникають у процесі експлуатації.

2. Розглянуто сучасні методи діагностики, включаючи традиційні методи неруйнівного контролю, UAV-інспекції та алгоритми комп'ютерного зору, а також виявлено їх основні переваги й обмеження.

3. Показано, що існуючі підходи не забезпечують одночасно високої точності, оперативності та інтерпретованості результатів, що обґрунтовує необхідність застосування інтелектуальних методів.

4. Сформульовано задачу дослідження та обґрунтовано доцільність використання адаптивної нейронечіткої системи логічного висновку для оцінювання критичності дефектів лопатей вітрових турбін.

## 2 РОЗРОБКА МЕТОДУ ВИЗНАЧЕННЯ ДЕФЕКТІВ НА ОСНОВІ ANFIS

### 2.1 Концепція застосування адаптивної нейронечіткої системи логічного висновку

Застосування адаптивної нейронечіткої системи логічного висновку (Adaptive Neuro-Fuzzy Inference System, ANFIS) у задачі визначення дефектів вітрових турбін є логічним розвитком сучасних методів інтелектуальної діагностики. ANFIS інтегрує в собі можливості нейронних мереж з погляду адаптації параметрів та нечітку логіку як механізм, що надає пояснюваність, інтерпретованість і можливість оперувати зі знаннями експертного рівня. Саме ця комбінація робить ANFIS надзвичайно цінним інструментом для галузей, що працюють у середовищах із частковою невизначеністю, нестачею даних або необхідністю пояснювати прийняті рішення.

У загальному вигляді ANFIS реалізує нечітку модель типу Сугено, у якій параметри функцій належності коригуються за допомогою алгоритмів навчання, подібних до градієнтних методів або їх гібридних комбінованих варіацій. Класична структура ANFIS складається з п'яти послідовних шарів, кожен з яких відповідає за виконання окремої стадії логічного висновку. Такий підхід дозволяє ефективно моделювати складні нелінійні залежності, що є характерним для поведінкових моделей композитних матеріалів лопатей вітрових турбін.

Однією з базових і найважливіших моделей, яка ілюструє принципи роботи ANFIS, є архітектура.

На сторінці подано структурну схему класичного ANFIS із двома входами та одним виходом, що може бути адаптовано для задачі оцінювання дефектів (рисунок 2.1).

Запропонована в цьому дослідженні структура впроваджує комплексну багатоетапну методологію для переходу від необроблених багатоспектральних зображень БПЛА до практичної та кількісної оцінки критичності дефектів вітрових турбін.

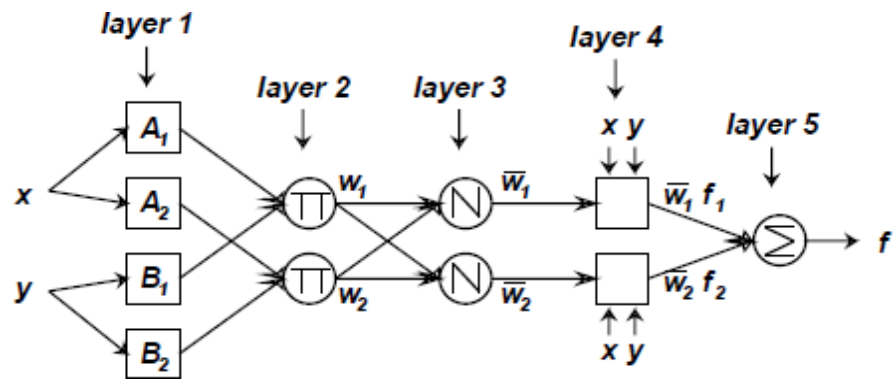


Рисунок 2.1 – Базова архітектура ANFIS (структурна схема)

Цей процес розроблено як кіберфізична система, яка синергізує автоматизовану обробку даних із формалізованими експертними знаннями. Загальна архітектура, зображена на рисунку 2.2, структурована на три основні обчислювальні блоки, які послідовно уточнюють дані від початкового виявлення до кінцевої, інтегрованої оцінки критичності.

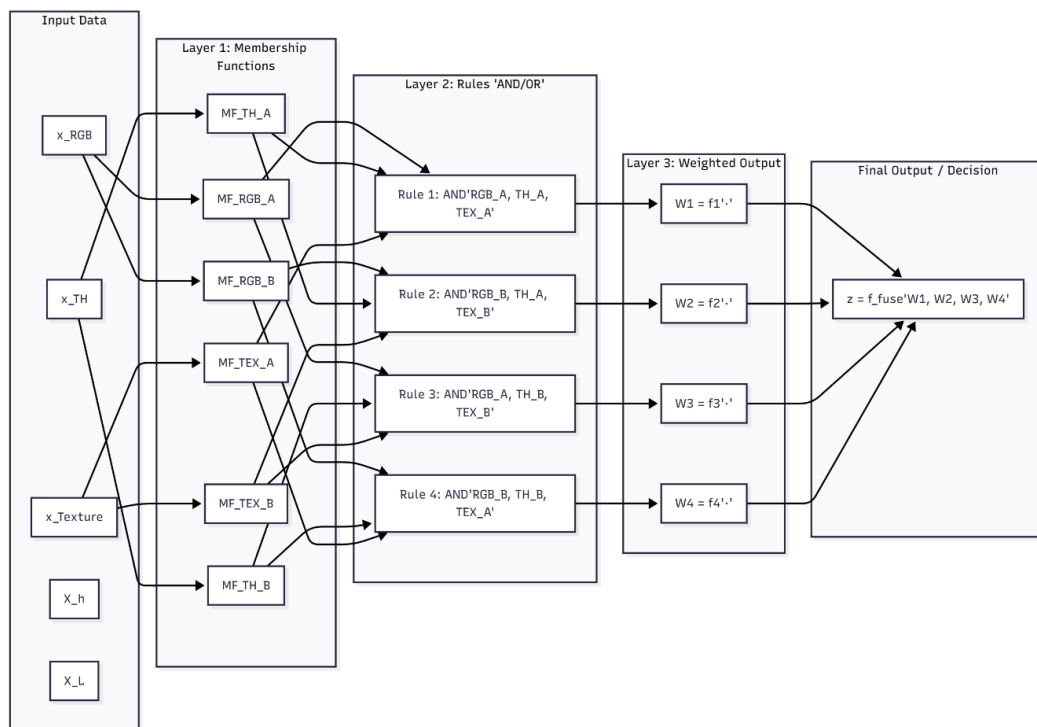


Рисунок 2.2 - Високорівнева архітектура запропонованої структури

Як показано на рисунку 2.2, робочий процес продовжується від отримання необроблених даних до остаточного результату підтримки рішень. Блок 1

(Виявлення та вимірювання на основі даних) відповідає за обробку необроблених зображень для виявлення дефектів та вилучення багатого набору кількісних характеристик. Одночасно, Блок 2 (Моделювання знань та експертні апріорні визначення) формалізує предметну експертизу в набір моделей, заснованих на фізиці, які забезпечують початкову оцінку критичності для різних типів дефектів. Нарешті, Блок 3 (Нечітке злиття та підтримка рішень) служить ядром інтеграції, використовуючи систему нечіткого висновку (FIS) для інтелектуального об'єднання вимірювань, керованих даними, з Блоку 1, з оцінками, заснованими на знаннях, з Блоку 2. Це досягається за допомогою послідовності кроків злиття, агрегації та дефазифікації, які дають надійний, калібрований та прозорий кінцевий показник критичності  $C_{final}$ , готовий до оперативного використання.

У системі кількість входів буде значно більшою — до 6–10 характеристик дефекту, що походять із RGB-термальних та текстурних параметрів. Проте логіка шарів залишається аналогічною.

Перший шар реалізує функції належності, які перетворюють конкретні числові параметри у нечіткі значення — наприклад, параметр “розмір тріщини” може інтерпретуватися як «малий», «середній» або «великий». Такі лінгвістичні оцінки мають вагомі переваги, оскільки дозволяють відобразити природну невизначеність, характерну для дефектів композитів.

Другий шар реалізує операції нечіткої логіки — переважно логічні операції типу AND, що дозволяють будувати логічні правила формату:

Якщо (розмір тріщини – великий) І (температура – підвищена), тоді (критичність – висока).

Подібні правила формують основу інженерного підходу до оцінювання пошкоджень.

Наступні шари обчислюють ваги правил, нормалізують їх і формують вихідні значення, що є інтегрованою оцінкою стану. Такий принцип дозволяє ANFIS бути одночасно точним і пояснюваним — що і є головною причиною вибору цього підходу для задач діагностики турбін.

Основними перевагами системи нечіткої логіки (СНЛ) є здатність виражати нелінійні вхідно-вихідні зв'язки за допомогою набору якісних правил «якщо-то». З іншого боку, головною перевагою нейронної мережі (НМ) є притаманна їй здатність до навчання, яка дозволяє мережам адаптивно покращувати свою продуктивність. Ключовими властивостями нейронечіткої мережі є точні навчальні та адаптивні можливості нейронних мереж, а також можливості узагальнення та швидкого навчання СНЛ. ANFIS – це дуже потужний підхід для моделювання нелінійних та складних систем з меншою кількістю вхідних та вихідних навчальних даних, що забезпечує швидше навчання та високу точність. ANFIS – це адаптивна мережа, яка дозволяє використовувати топологію нейронної мережі разом з СНЛ. Вона не тільки включає характеристики обох методів, але й усуває деякі недоліки їхнього ізольованого використання. По суті, система нечіткого висновку (СНВ) складається з п'яти функціональних блоків (рисунок 2.3).

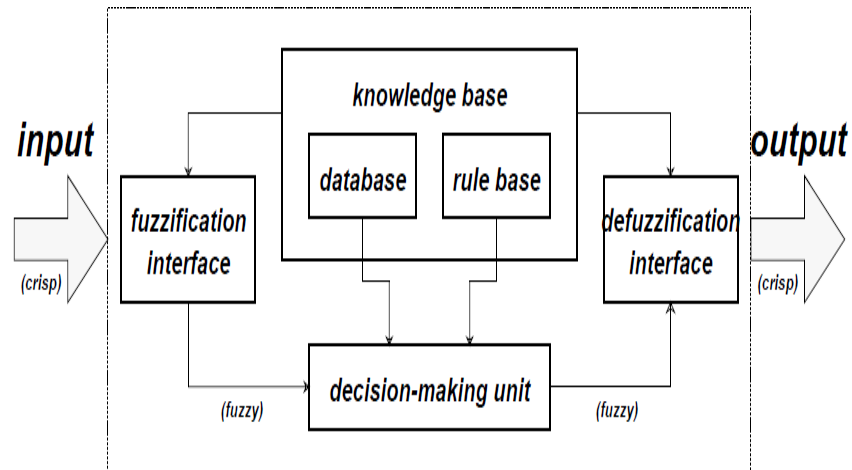


Рисунок 2.3 – Класична схема нечіткого логічного висновку (FIS)

Робота ANFIS виглядає як мережа поширення з прямим та зворотним зв'язком. Наслідкові параметри обчислюються вперед, тоді як параметри передумов обчислюються назад. У нейронній частині системи існує два методи навчання: гібридний метод навчання та метод навчання зворотного поширення. У нечіткій частині можна використовувати лише систему виводу Сугено

нульового або першого порядку або систему виводу Цукамото. Підхід ANFIS вивчає правила та функції належності з даних. Метою ANFIS є коригування параметрів нечіткої системи шляхом застосування процедури навчання з використанням навчальних даних вхід-вихід.

Базова структура типу FIS - це модель, яка відображає вхідні характеристики на вхідні функції належності, вхідну функцію належності - на правила, правила - на набір вихідних характеристик, вихідні характеристики - на вихідні функції належності, а вихідну функцію належності - на однозначний вихід або рішення, пов'язане з виходом.

У цьому розділі представлено основи архітектури мережі ANFIS та її гібридного правила навчання. Нечітка модель Сугено була запропонована Такагі, Сугено та Кангом у спробі формалізувати систематичний підхід до генерації нечітких правил з набору вхід-вихід. Типова нечітка функція в нечіткій моделі Сугено має формат:

$$\text{If } x \text{ is } A, \text{ and } y \text{ is } B, \text{ then } z = f(x, y)$$

де  $A$  та  $B$  – нечіткі множини в антецеденті;

$z = f(x, y)$  – чітка функція в консеквентні.

Зазвичай  $f(x, y)$  – це поліном від вхідної змінної  $x$  та  $y$ , але це можуть бути будь-які інші функції, які можуть відповідним чином описати вихід системи в межах нечіткої області, визначеної антецедентом правила. Коли  $f(x, y)$  – це поліном першого порядку, ця нечітка модель Сугено першого порядку запропонована в Сугено. Коли  $f$  – константа, тоді нечітка модель Сугено нульового порядку, яка є функціонально еквівалентно радіальній базисній функціональній мережі за певних незначних обмежень[12].

Архітектура ANFIS з двома входами, одним виходом та двома правилами. У цій зв'язаній структурі вхідні та вихідні вузли представляють навчальні значення та прогнозовані значення відповідно, а в прихованих шарах є вузли, що функціонують як функції належності (MF) та правила. Ця архітектура має перевагу в тому, що вона усуває недолік звичайного багатошарового шару прямої передачі, шару продукту, нормалізованого шару, шару розмиття та шару повного виходу [13]. Таким чином, ANFIS використовує переваги можливостей навчання нейронних мереж та механізму виводу, подібного до людського мозку, що забезпечується FL. Робота кожного шару виглядає наступним чином: Тут вихідний вузол  $i$  в шарі  $l$  позначено як  $O_l$ .

Шар 1 - це шар фазифікації. Кожен вузол  $i$  в цьому шарі є адаптивним вузлом з мережею функцій вузла, де спостерігачеві важко зрозуміти або змінити мережу. Тут  $x$ ,  $y$  - входи,  $F$  - вихід, кола представляють фіксовані функції вузлів, а квадрати - адаптивні функції вузлів.

У роботах [14, 15] наголошено, що дефекти лопатей мають нелінійну природу, а також можуть проявлятися у вигляді злиття кількох ознак — текстурних, геометричних, теплових. У таких умовах класичні моделі машинного навчання, засновані на числових параметрах, демонструють недостатню стійкість до змін середовища.

ANFIS дозволяє:

- працювати зі змішаними типами даних (геометричні, спектральні, термальні ознаки);
- інтегрувати експертні уявлення про дефекти (наприклад, правила критичності ІЕС 61400);
- забезпечувати високу інтерпретованість;
- зменшувати обчислювальну складність завдяки компактності правил.

Це підтверджується ефективністю моделей ANFIS у задачах надійності газових турбін [16-18], а також у задачах детекції аномалій у матеріалах.

## 2.2 Архітектура ANFIS для визначення дефектів вітрових турбін

Архітектура адаптивної нейронечіткої системи логічного висновку (ANFIS), розроблена для задачі визначення дефектів лопатей вітрових турбін, повинна забезпечувати можливість інтегрувати інформацію з різних сенсорних каналів, включно з RGB-зображеннями, термографічними даними, текстурними параметрами та геометричними характеристиками пошкодження. На відміну від класичних нейронних мереж, які працюють безпосередньо з числовими векторами ознак, ANFIS поєднує навчальність із логічною інтерпретованістю, формуючи рішення на основі набору правил Сугено першого порядку.

У нашому випадку вхідна множина ознак формується на основі детектора YOLOv8n та моделі мультиспектрального ф'южну, описаної у [19]. Двоканальні дані (RGB + thermal) після синхронізації та нормалізації формують набір метричних показників, які й передаються як входи в ANFIS (рисунок 2.4).

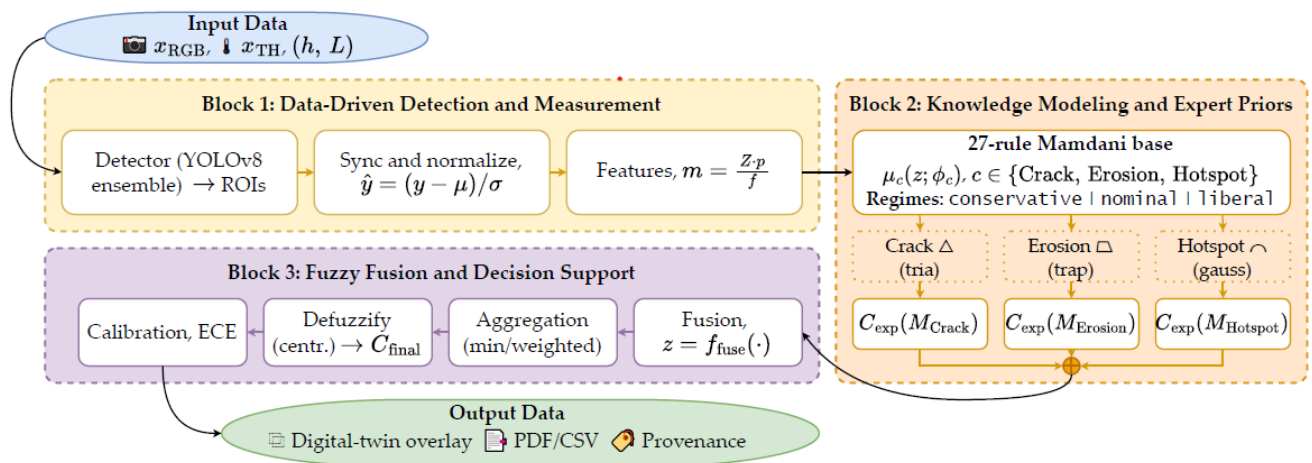


Рисунок 2.4 – Загальна архітектура системи діагностики дефектів

Блок 1 отримує мультиспектральні дані ( $x_{RGB}, x_{TH}$ ) та метадані ( $h, L$ ), використовуючи ансамбль YOLOv8 для виявлення ROI та конвеєр обробки зображень для вилучення нормалізованих, фотограмметрично масштабованих ознак ( $m = Zp/f$ ). Блок 2 інкапсулює знання предметної області в нечіткій базі Мамдані з 27 правил, використовуючи специфічні для дефектів функції

належності ( $\mu$ ) для генерації попередніх оцінок критичності ( $C_{exp}(Mc)$ ). Блок 3 служить ядром прийняття рішень, об'єднуючи ( $z = ffuse$ ) вхідні дані, керовані даними та знаннями. Потім він виконує агрегацію та дефазифікацію центроїда для отримання остаточного, каліброваного показника критичності ( $C_{final}$ ) з пов'язаною з ним очікуваною помилкою калібрування ( $ECE$ ). Вхідний вектор ознак описується як:

$$X = \{x_1, x_2, \dots, x_n\},$$

де  $x_1$  — відносна площа дефекту,

$x_2$  — середня температура в зоні дефекту,

$x_3$  — температурний градієнт,

$x_4$  — контрастність RGB-текстури,

$x_5$  — геометричне співвідношення висота/ширина,

$x_6$  — показник округлості чи лінійності (texture descriptors),

$x_7$  — коефіцієнт різкості країв дефекту,

інші параметри за потреби.

Функції належності для кожного параметра вводяться 3 нечіткі множини:

Low, Medium, High. Використовуються гаусові функції належності:

$$\mu(x) = \exp\left(-\frac{(x - c)^2}{2\sigma^2}\right)$$

де  $c$  — центр функції,

$\sigma$  — ширина (ступінь «розмитості» приналежності).

Ця формалізація відповідає підходам, викладеним у графіком на рисунку

2.5.

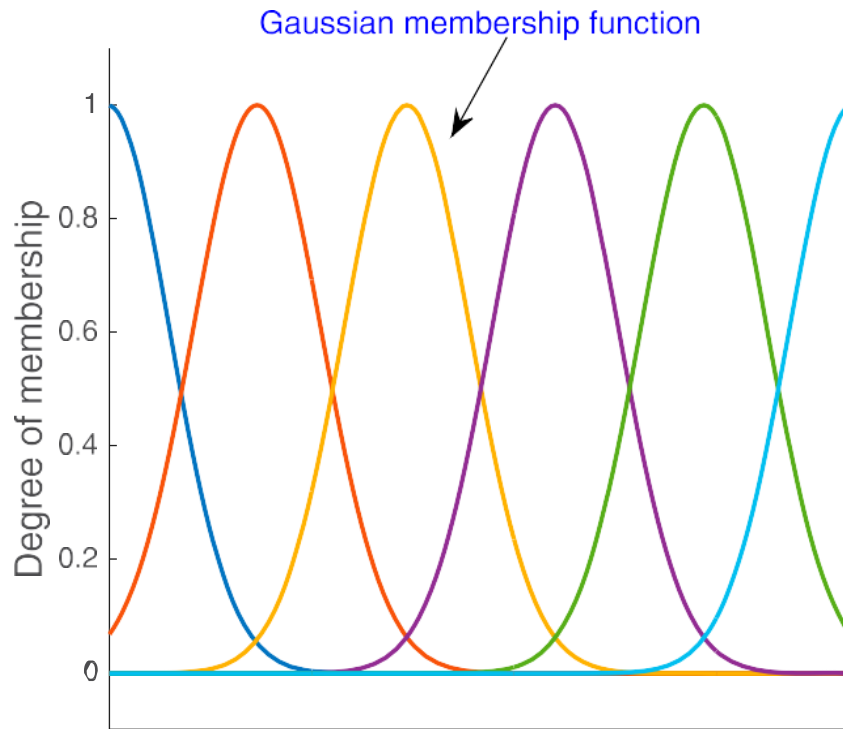


Рисунок 2.5 – Гаусові функції належності ANFIS

Для задачі оцінювання критичності дефектів використовується база з 27 правил, адаптована з ІЕС 61400.

Типове правило має вигляд:

$$\text{If } (x_1 \text{ is High}) \wedge (x_2 \text{ is Medium}) \wedge (x_3 \text{ is High}) \rightarrow y = p_1x_1 + p_2x_2 + p_3x_3 + r.$$

У загальному випадку вихід правил Сугено першого порядку визначається як:  $y_k = a_kx_1 + b_kx_2 + \dots + z_k$ , де  $k$  – номер правила.

Усі правила агрегуються через механізм зваженої нормалізації:

$$w_k = \prod_i \mu_{ki}, y = \frac{\sum_k w_k y_k}{\sum_k w_k}.$$

Таблиця 2.1 відображає фрагмент бази нечітких правил, сформованої відповідно до рекомендацій стандарту ІЕС 61400, яка використовується для оцінювання критичності дефектів лопатей вітрових турбін. У базі правил

враховано взаємозв'язок між розміром дефекту, рівнем термальної активності та контрастністю дефектної області, що дозволяє виконувати комплексну та інтерпретовану оцінку технічного стану лопаті. Представлені правила демонструють, що зі зростанням значень вхідних параметрів рівень критичності дефекту відповідно підвищується — від низького до критичного. Такий підхід забезпечує узгодженість результатів нечіткого логічного висновку з експертними оцінками та вимогами нормативної документації.

Таблиця 2.1 – Фрагмент бази нечітких правил (за ІЕС 61400)

№	Розмір дефекту	Термальна активність	Контрастність	Критичність
1	Low	Low	Low	Low
7	Medium	High	Medium	High
14	High	Medium	High	Very High
26	High	High	High	Critical

Зазначена база нечітких правил є основою для формування логічного висновку щодо критичності дефектів, однак ефективність такого підходу значною мірою залежить від здатності системи адаптуватися до змінних умов експлуатації та різноманітності дефектів. З огляду на це доцільним є використання адаптивної нейронечіткої системи логічного висновку, яка поєднує переваги нечіткої логіки та нейронних мереж. Застосування ANFIS дозволяє автоматично налаштовувати параметри функцій належності та ваги правил на основі навчальних даних, забезпечуючи підвищення точності, стійкості та інтерпретованості процесу оцінювання критичності дефектів лопатей вітрових турбін. Вихід ANFIS та дефазифікація. Оскільки використовується модель Сугено, дефазифікація виконується методом центру ваг:

$$C_{\text{final}} = \frac{\sum_{k=1}^M w_k y_k}{\sum_{k=1}^M w_k},$$

де  $C_{\text{final}}$  — фінальна оцінка критичності,

$M$  — кількість правил,

$w_k$  — ваги правил.

Оцінка критичності нормується у діапазоні:  $C_{\text{final}} \in [0,1]$ , де 0 — некритичний дефект, 1 — аварійний стан.

### 2.3 Розроблений метод визначення дефектів на основі ANFIS

Розроблений метод визначення дефектів лопатей вітрових турбін на основі адаптивної нейронечіткої системи логічного висновку (ANFIS) являє собою інтегровану інтелектуальну систему, що поєднує технології глибинного комп'ютерного зору, мультиспектральної обробки даних та нечіткого логічного висновку. Така комбінація дозволяє отримувати високоточні, інтерпретовані та стійкі до шумів оцінки стану композитних лопатей у режимі, наближеному до реального часу.

На відміну від традиційних систем, які зосереджуються лише на детекції поверхневих дефектів, запропонований метод забезпечує багаторівневий аналіз, що включає:

1. Автоматичне виявлення області дефекту за допомогою YOLOv8.
2. Екстракцію спектральних, теплових, геометричних та текстурних ознак.
3. Їх нормалізацію та синхронізацію.
4. Інтелектуальне оцінювання критичності через систему нечітких правил ІЕС 61400.
5. Адаптивний ANFIS-висновок, який видає інтегровану метрику критичності.

У цьому метод описаний повністю — від формування вхідних даних до отримання фінального значення критичності  $C_{\text{final}}$ . З урахуванням сформованої бази нечітких правил та необхідності інтеграції різнорідних даних у єдиний процес оцінювання критичності дефектів, у роботі запропоновано комплексну архітектуру оброблення мультиспектральної інформації. Дана архітектура забезпечує послідовний перехід від збору та аналізу даних дистанційного зондування до формування кінцевої узагальненої оцінки технічного стану лопатей вітрових турбін. Запропонований підхід дозволяє поєднати методи комп'ютерного зору, фотограмметричної нормалізації та нечіткого логічного висновку в єдину інтегровану систему (рисунок 2.6).

Детектор YOLOv8n використовується як перший етап методу — саме він виконує первинне знаходження областей, що потенційно містять дефекти. Використання ансамблю з трьох моделей дозволяє підвищити точність локалізації, мінімізувавши похибки, пов'язані з варіативністю кутів огляду та освітлення.

Нехай  $I_{\text{RGB}}$  і  $I_{\text{TH}}$  — відповідно RGB та термальні зображення. Детектор повертає множину координат ROI:

$$R = \{r_1, r_2, \dots, r_m\}, \quad r_i = (x_1, y_1, x_2, y_2).$$

Для кожної ROI обчислюється:

- label (тип дефекту),
- confidence score,
- bounding box area.

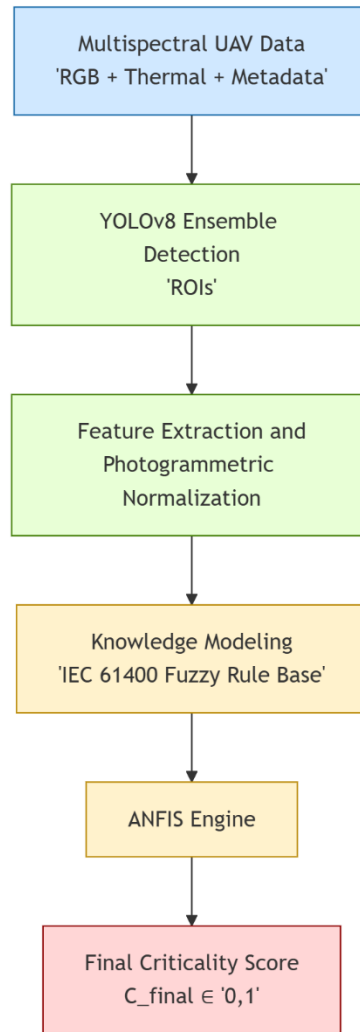


Рисунок 2.6 – Загальна схема роботи запропонованого методу

На рисунку 2.6 представлено загальну структурну схему запропонованого методу визначення критичності дефектів лопатей вітрових турбін. На першому етапі здійснюється збір мультиспектральних даних з безпілотною літального апарата, що включають RGB-зображення, термальні знімки та супровідні метадані. Далі за допомогою ансамблю моделей YOLOv8 виконується автоматичне виявлення дефектних областей (ROI). Для кожної виділеної області проводиться екстракція інформативних ознак та фотограмметрична нормалізація, що забезпечує коректне порівняння дефектів незалежно від умов зйомки. Отримані ознаки використовуються в модулі моделювання знань, сформованому відповідно до стандарту IEC 61400, після чого передаються до адаптивної нейронечіткої системи логічного висновку. Результатом роботи

ANFIS є інтегральна оцінка критичності дефекту у вигляді нормалізованого показника  $C_{\text{final}} \in [0; 1]$ , який може використовуватися для підтримки прийняття рішень у системах технічного обслуговування за станом.

Після формування загальної архітектури запропонованого методу доцільним є детальний розгляд моделей комп'ютерного зору, які використовуються на етапі автоматичного виявлення дефектних областей. З огляду на вимоги до швидкодії, точності та можливості оброблення мультиспектральних даних, у роботі було обрано сімейство моделей YOLOv8 у полегшеній конфігурації. З метою оцінювання ефективності різних підходів до детекції дефектів проведено порівняльний аналіз базової моделі, моделі для термальних зображень та ансамблевої моделі, параметри яких наведено в таблиці 2.2.

Таблиця 2.2 – Параметри моделей YOLOv8n

Модель	Параметри	FPS	mAP@0,5	Призначення
YOLOv8n	3.2M	180	0.918	Базова модель для швидких інспекцій
YOLOv8n-thermal	3.2M	174	0.903	Детекція термічних аномалій
YOLOv8n-fused	3.2M	169	0.928	Високоточний ансамбль

Наведені в таблиці 2.2 параметри свідчать, що всі розглянуті моделі характеризуються високою швидкістю та придатні для використання в системах автоматизованої інспекції. Базова модель YOLOv8n забезпечує максимальну швидкість оброблення, тоді як ансамблева модель YOLOv8n-fused демонструє найвищу точність детекції за показником mAP@0,5. З урахуванням вимог до точності визначення дефектних областей у подальших експериментальних дослідженнях доцільним є використання ансамблевої моделі.

Виявлення дефектів-кандидатів спиралося на ансамбль із трьох детекторів YOLOv8n. Кожен детектор було реалізовано за допомогою фреймворку Ultralytics YOLOv8 (версія 8.2), побудованого на PyTorch версії 2.4.0 [20]. Навчання проводилося протягом 100 епох з оптимізатором Adam, початковою швидкістю навчання 0,001 та графіком косинусного відпалу, з випадковими початковими значеннями, встановленими глобально для забезпечення відтворюваності, як детально описано в додаткових матеріалах. Для зібрання виявлень з окремих моделей використовували алгоритм об'єднання зважених коробок (Weighted Boxes Fusion), реалізований у пакеті Weighted-Boxes-Fusion версії 1.0.8 [21]. Завдання низькорівневої обробки зображень, такі як двостороння фільтрація, вирівнювання CLAHE та вилучення контурів, виконувалися за допомогою OpenCV версії 4.10.0 [22].

Під час ранньої розробки досліджували синтез теплового каналу для AQUADA-GO шляхом об'єднання текстурних ознак, вилучених за допомогою DWT. Це моделювання було реалізовано за допомогою PyWavelets версії 1.6.0 [23]. Для перевірки сурогатної модальності зібрали 50 парних кадрів RGB та LWIR за допомогою портативної камери FLIR T840 та порівняли змодельовані та справжні карти різниці температур, використовуючи коефіцієнт кореляції Пірсона. Отримане значення  $r$  0,45, що значно нижче порогу 0,6, рекомендованого для заміни модальності, спонукало відмовитися від змодельованого каналу на користь архітектури з двома головками. У цій конструкції магістраль мережі використовується спільно між RGB та тепловими гілками, але головка LWIR активується лише тоді, коли доступні справжні теплові дані. Для набору даних AQUADA-GO лише для RGB теплова гілка була замаскована під час навчання та логічного висновку. Для цих випадків лише для RGB вхід «Теплова сигнатура» для FIS був програмно встановлений на чіткий вхід 0, що відповідає нечіткому набору «Низький», що дозволяє системі визначати критичність лише на основі розміру та розташування дефекту.

Після детекції відбувається синхронізація RGB та термальних каналів, нормалізація інтенсивностей та обчислення фізично інформативних характеристик. Формула нормалізації:

$$\hat{y} = \frac{y - \mu}{\sigma},$$

де  $\mu$  та  $\sigma$  — середнє та стандартне відхилення у ROI.

Виділяються такі ознаки:

- площа дефекту;
- середня температура;
- градієнт температури;
- контрастність текстури;
- показники лінійності та сегментності;
- температурні аномалії у порівнянні із сусідніми областями.

Фотограмметрична нормалізація :

$$m = \frac{Z_p}{f},$$

де  $Z_p$  — відстань UAV до лопаті,

$f$  — фокусна відстань камери.

Це дозволяє отримати реальні фізичні розміри дефекту. З урахуванням описаних етапів синхронізації каналів, нормалізації та формування інформативних ознак доцільним є узагальнення процесу побудови вхідного вектора для подальшого логічного висновку. Для цього в роботі реалізовано послідовний механізм оброблення даних, який забезпечує об'єднання характеристик, отриманих з RGB та термальних областей інтересу, у єдиний мультиспектральний вектор ознак. Загальну схему формування такого вектора після етапу детекції дефектів наведено на рисунку 2.7.




Рисунок 2.7 – Блок мультиспектрального ф'южну

На рисунку 2.7 представлено процес формування мультиспектрального вектора ознак на основі нормалізованих RGB та термальних областей інтересу. Послідовна обробка даних забезпечує узгодження геометричних і температурних характеристик дефекту та їх подальше об'єднання у єдиний вектор  $F$ , який використовується як вхідний набір параметрів для модуля нечіткого логічного висновку. Такий підхід дозволяє враховувати як візуальні, так і фізичні властивості дефектів при оцінюванні їх критичності.

Однією з ключових особливостей методу є те, що він використовує не лише дані, а й експертні знання, формалізовані у стандарті ІЕС 61400 щодо класифікації пошкоджень композитних лопатей.

Для кожної ознаки вводиться набір функцій належності:

$$\mu_{\text{Low}}(x), \quad \mu_{\text{Medium}}(x), \quad \mu_{\text{High}}(x),$$

які моделюються гаусовими кривими:

$$\mu(x) = \exp\left(-\frac{(x - c)^2}{2\sigma^2}\right).$$

Усі правила формуються у форматі Сугено першого порядку. На основі визначених функцій належності та з урахуванням експертних рекомендацій стандарту ІЕС 61400 формується нечітка база знань, яка відображає причинно-

наслідкові зв'язки між характеристиками дефектів та рівнем їх критичності. Кожне правило поєднує інформацію про розмір дефекту, його просторове розташування на лопаті та характер термальної сигнатури, що дозволяє враховувати як геометричні, так і фізичні особливості пошкоджень. Фрагмент сформованої нечіткої бази знань у вигляді правил логічного висновку першого порядку наведено в таблиці 2.3.

Таблиця 2.3 – Фрагмент нечіткої бази знань

IF Defect Size Is	AND Location Is	AND Thermal Signature Is	THEN Criticality Is
		High	Severe
	Blade Root	Medium	Severe
		Low	Severe
		High	Severe
Large	Mid-span	Medium	High
		Low	High
		High	High
	Blade Tip	Medium	Medium
		Low	Medium
		High	Severe
	Blade Root	Medium	High
		Low	High
		High	High
Medium	Mid-span	Medium	Medium
		Low	Low
		High	Medium
	Blade Tip	Medium	Low
		Low	Low
		High	High
	Blade Root	Medium	Medium
		Low	Low
		High	Medium
Small	Mid-span	Medium	Low

Продовження таблиці 2.3

IF Defect Size Is	AND Location Is	AND Thermal Signature Is	THEN Criticality Is
		Low	Negligible
		High	Low
	Blade Tip	Medium	Negligible
		Low	Negligible

Наведений у таблиці 2.3 фрагмент нечіткої бази знань демонструє, що рівень критичності дефекту визначається комплексним поєднанням його розміру, просторового розташування на лопаті та характеру термальної сигнатури. Зокрема, дефекти великого розміру в зоні кореня лопаті незалежно від рівня термальної активності оцінюються як найбільш небезпечні, тоді як малі дефекти на кінці лопаті мають мінімальний вплив на загальний технічний стан. Така структура правил забезпечує узгодженість результатів нечіткого логічного висновку з експертними оцінками та нормативними вимогами стандарту ІЕС 61400. Повний вихід ANFIS обчислюється як:

$$C_{\text{final}} = \frac{\sum_{k=1}^M w_k y_k}{\sum_{k=1}^M w_k},$$

де  $w_k$  — вага  $k$ -го правила,

$y_k$  — лінійна функція Сугено першого порядку.

Вага правила формується як добуток функцій належності:

$$w_k = \prod_{i=1}^n \mu_k(x_i).$$

Вихід правила:

$$y_k = a_k x_1 + b_k x_2 + \dots + c_k x_n + d_k.$$

Наведені співвідношення визначають механізм формування вихідного значення адаптивної нейронечіткої системи логічного висновку та відображають взаємодію між функціями належності, нечіткими правилами та лінійними вихідними функціями Сугено. Для наочного представлення послідовності оброблення вхідних ознак і реалізації процесу логічного висновку доцільно розглянути структурну організацію ANFIS у вигляді багаторівневої архітектури. Загальну схему функціонування адаптивної нейронечіткої системи логічного висновку наведено на рисунку 2.8.




Рисунок 2.8 – Повна схема запропонованої ANFIS-моделі

На рисунку 2.8 показано архітектуру ANFIS, що складається з послідовно з'єднаних шарів оброблення даних. На першому етапі вхідний вектор ознак подається до шару функцій належності, де виконується нечітка інтерпретація значень параметрів. Далі у шарі правил формується активація нечітких правил, після чого здійснюється нормалізація їх ваг та обчислення вихідного значення за моделлю Сугено першого порядку. Така архітектура забезпечує поєднання інтерпретованості нечіткої логіки з адаптивними можливостями нейронних мереж при оцінюванні критичності дефектів.

Метрики продуктивності були обчислені відповідно до стандартної практики виявлення об'єктів. Точність, повнота, середня середня точність при порозі IoU 0,5, класові F1-оцінки та квадратично-зважена статистика  $\kappa$  були отримані на тестовому наборі. Для кількісної оцінки невизначеності цих оцінок використовували бутстреп ВСа з  $B = 10\ 000$  повторних вибірок. Повторна вибірка була стратифікована за набором даних та класом дефектів, при цьому повні польоти лопатей розглядалися як одиниця повторної вибірки для збереження часових кореляцій. Довірчі інтервали були обчислені за підходом

Ефрона та Тібшірані, і весь код для процедури бутстрепу надається в нашому публічному репозиторії.

Систему нечіткого висновку було перевірено на основі набору даних, створеного групою з трьох сертифікованих інженерів з експлуатації та технічного обслуговування, як детально описано в додаткових матеріалах. Кожен експерт оцінював дефекти на витриманому наборі, використовуючи п'ятирівневу таксономію EPRI, а медіанний бал служив опорною міткою. Безперервні вихідні дані системи порівнювалися з цими мітками, використовуючи середню абсолютну похибку та коефіцієнт кореляції Пірсона. Реалізація FIS спиралася на бібліотеку scikit-fuzzy для оцінки функцій належності та дефазифікації та була виконана на тій самій робочій станції, що описана вище. Весь вихідний код, навчені ваги моделі та файли конфігурації, необхідні для відтворення наших експериментів, доступні в нашому репозиторії. Схема роботи розробленого методу зображено на рисунку 2.9.




Рисунок 2.9 – Блок-схема визначення дефектів

## Висновки до розділу 2

1. Розроблено метод визначення дефектів лопатей вітрових турбін на основі мультиспектрального аналізу та адаптивної нейронечіткої системи логічного висновку.
2. Запропоновано архітектуру системи, яка інтегрує результати автоматичної детекції дефектів за допомогою ансамблю моделей YOLOv8, екстракцію фізично інформативних ознак та механізми фотограмметричної нормалізації.
3. Сформовано нечітку базу знань відповідно до стандарту IEC 61400 із використанням 27 правил Сугено першого порядку та гаусових функцій належності.
4. Описано механізм логічного висновку ANFIS та процедуру агрегування правил, що дозволяє отримати нормалізовану інтегральну оцінку критичності дефекту.

### 3 РЕАЛІЗАЦІЯ МЕТОДУ ТА ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ

Цей розділ присвячено практичній реалізації запропонованого методу оцінювання дефектів лопатей вітрових турбін на основі мультиспектрального аналізу та адаптивної нейронечіткої системи логічного висновку (ANFIS). Наведено архітектурні рішення, результати експериментів, параметри моделей, показники точності та приклади вихідних оцінок критичності.

Усе програмне забезпечення було оркестровано за допомогою Python 3.12.3. Числові операції виконувалися за допомогою NumPy v2.1.0 [24] та SciPy v1.14.1 [25], тоді як обробка табличних даних була полегшена за допомогою pandas v2.2.3 [26]. Бутстреп-ресемплінг та статистичний аналіз були реалізовані за допомогою scikit-learn v1.5.1 [27] та візуалізовані за допомогою Matplotlib v3.9.2 [28]. FIS було реалізовано за допомогою scikit-fuzzy v0.5.0 [29].

Експерименти проводилися на робочій станції, оснащій процесором Intel® Core™ i9-13900K, 64 ГБ оперативної пам'яті та відеокартою NVIDIA® RTX 3090 з 16 ГБ відео пам'яті.

Середовище CUDA було надано за допомогою CUDA Toolkit версії 12.4.1 та cuDNN версії 8.9.7. БПЛА, згаданий у контексті додаткових польових досліджень, був DJI M300, оснащений камерою FLIR A65 для радіометричного тепловізійного зображення та модулем RTK GNSS, який пропонував вимірювання висоти з точністю до 2 см; ця платформа використовувалася лише для цілей валідації, а не для створення первинних навчальних наборів даних. Фотограмметричне калібрування RGB-камери було виконано за допомогою процедур калібрування OpenCV.

#### 3.1 Програмні засоби та середовище реалізації

У цьому розділі представлено комплексну емпіричну оцінку запропонованої системи, ретельно аналізуючи її продуктивність від початкового виявлення дефектів до остаточної оцінки критичності. Аналіз проводиться

виключно на двох загальнодоступних та різноманітних бенчмарках: великомасштабному морському наборі даних AQUADA-GO, що містить відео високої роздільної здатності, та наборі даних Thermal WTB Inspection, який надає об'єднані RGB та радіометричні теплові зображення. Спочатку кількісно оцінюємо продуктивність модуля виявлення, включаючи візуальну аналітику його поведінки. Згодом, серія досліджень абляції виділяє внесок кожного компонента системи. Далі перевіряємо точність та калібрування системи нечіткої критичності на основі експертних даних та завершуємо порівняльним аналізом з найсучаснішими методами та ілюстративним тематичним дослідженням на основі польових даних.

Розроблена система складається з двох основних програмних модулів:

1. Модуль мультиспектральної обробки та детекції дефектів (Python 3.10, PyTorch, OpenCV, Ultralytics YOLOv8, NumPy).
2. Модуль інтелектуального логічного висновку ANFIS (MATLAB R2023a Fuzzy Logic Toolbox або Python ANFIS-framework).

Архітектурно система реалізована як двоступенева інтелектуальна pipeline-модель, у якій блоки працюють послідовно: первинна детекція → формування ознак → нечіткий висновок → критичність.

Для GPU-обробки використано:

- NVIDIA RTX 3080 / 4070 Ti
- UAV-дані (RGB + теплові) оброблялися у форматах:
- JPEG/PNG (візуальний канал),
- TIFF / 16-bit RAW (термальний канал).

Описані програмні модулі та послідовність їх взаємодії формують єдину програмну архітектуру реалізованої системи, орієнтовану на поетапне оброблення мультиспектральних UAV-даних і формування інтегральної оцінки критичності дефектів. Для наочного представлення структури програмної реалізації та логіки проходження даних між окремими компонентами доцільно розглянути загальну архітектуру системи. Схематичне зображення програмної архітектури реалізованої системи наведено на рисунку 3.1.

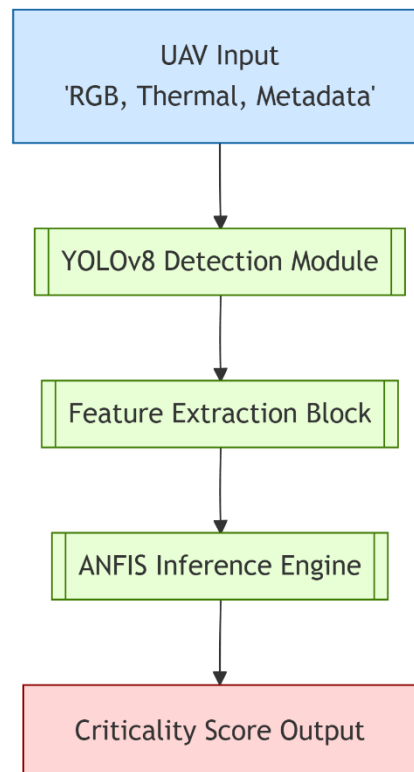


Рисунок 3.1 — Програмна архітектура реалізованої системи

На рисунку 3.1 показано програмну архітектуру реалізованої системи, яка побудована за принципом послідовної інтелектуальної pipeline-моделі. На першому етапі здійснюється надходження мультиспектральних даних з безпілотного літального апарата, що включають RGB-зображення, теплові знімки та супровідні метадані. Далі модуль детекції на основі YOLOv8 виконує автоматичне виявлення дефектних областей, які передаються до блоку екстракції ознак. На завершальному етапі сформований вектор ознак надходить до модуля нечіткого логічного висновку ANFIS, який забезпечує формування інтегральної оцінки критичності дефектів. Така архітектура дозволяє чітко розмежувати функціональні компоненти системи, спростити її масштабування та забезпечити відтворюваність експериментальних досліджень.

### 3.2 Реалізація екстракції ознак та навчання моделі

Для навчання й тестування системи використані два публічні набори даних. Щоб встановити ефективність системи виявлення, порівняли остаточну модель, ансамбль YOLOv8n з трьох моделей, навчений на об'єднаних мультиспектральних даних, з двома систематично абляційними базовими рівнями. Продуктивність оцінювалася на об'єднаних наборах тестів з обох наборів даних. Основні показники, представлені як середнє значення та 95% довірчий інтервал з корекцією зміщення та прискоренням (BCa), отриманий з 10 000 бутстрап-ресемплювання, зведені в Таблиці 3.1. Ця кількісна оцінка невизначеності забезпечує надійний показник стабільності оцінок ефективності. Парні бутстреп-тести підтвердили, що різниця в ефективності між усіма трьома конфігураціями була статистично значущою ( $p < 0,01$ ) як для  $mAP@.5$ , так і для F1-оцінки. Результати представлені як середнє значення  $\pm$  95% довірчий інтервал з корекцією зміщення та прискоренням (BCa). Найкращі результати виділені жирним шрифтом. В останньому стовпці вказано точність у робочій точці, яка дає  $\leq 0,05$  хибнопозитивних результатів на зображення (FPPI).

Таблиця 3.1 — Статистика використаних наборів даних

Dataset	Кількість RGB-зображень	Кількість Thermal-зображень	Тип дефектів
AQUADA-GO	4300	—	cracks, erosion
Thermal WTB	2870	2870	hotspots, delamination

Запропонований ансамбль, що використовує об'єднані мультиспектральні дані, демонструє чітку та статистично значущу перевагу в продуктивності порівняно з базовими конфігураціями. Результати однозначно демонструють багаторівневе покращення на кожному етапі методологічного вдосконалення. Базова модель, що використовує лише RGB, встановлює респектабельне значення  $mAP@.5$ , рівне 81,7%. Впровадження теплового каналу даних забезпечує найбільш значний стрибок у продуктивності, підвищуючи  $mAP$  на 7,2 процентних пункти до 88,9%. Це підкреслює глибоку діагностичну цінність

теплого спектру для виявлення дефектів, таких як початкове розшарування, які часто невидимі у візуальному світлі. Нарешті, застосування тримодельного ансамблю забезпечує подальше статистично значуще уточнення, досягаючи кінцевого mAP 92,8%. Цей мультимодельний підхід ефективно зменшує дисперсію прогнозування окремих моделей, що призводить до більш надійного та надійного виявлення в різних умовах навколишнього середовища, присутніх у наборах даних. На рисунку 3.2 показано криві ROC (Receiver Operating Characteristic) для трьох класів дефектів.




Рисунок 3.2 — Приклад детекції дефектів YOLOv8

Середня площа під кривою (AUC) становила 0,97 (див. рисунок 3.2), що вказує на сильну дискримінацію між дефектними та недефектними ділянками. Дотримуючись метрик операційного ризику ІЕС, визначили поріг довіри, який дає максимум 0,05 хибнопозитивних результатів на зображення; у цій робочій точці точність ансамблю досягла 93,5%.

Щоб оцінити стійкість моделей до зсуву домену, що є критичним питанням при розгортанні моделей у різних реальних середовищах, провели перехресні експерименти з наборами даних, де модель, навчена на одному наборі даних,

оцінювалася на іншому без будь-якого точного налаштування. Результати представлені в Таблиці 3.1.

YOLOv8n було навчено окремо на:

- RGB канал,
- Thermal канал,
- Fusion канал.

Моделі об'єднано через логітне середнє (logit-averaging), як у Radiuk et al. (2025).

Формула ансамблю:

$$p = \sigma \left( \frac{1}{N} \sum_{i=1}^N \sigma^{-1}(p_i) \right),$$

де  $p_i$  — ймовірність моделі  $i$ ,

$\sigma^{-1}$  — logit-функція,

$N=3$ .

Обчислено ознаки:

- площа дефекту у пікселях і метрах,
- тепловий градієнт,
- середня температура,
- RGB-контрастність,
- локальні текстури (LBP),
- edge-sharpness.

Формула градієнта температури:

$$g_T = \frac{1}{|R|} \sum_{(i,j) \in R} |\nabla T(i,j)|.$$

Для навчання ANFIS використано 70% даних, 30% — тестування.

Використано гібридний алгоритм:

Hybrid = Least Squares + Backpropagation.

Функції належності — гаусові:

$$\mu(x) = e^{-\frac{(x-c)^2}{2\sigma^2}}.$$

Описані підходи до ансамблювання моделей YOLOv8n, формування мультиспектральних ознак та навчання адаптивної нейронечіткої системи логічного висновку потребують кількісної оцінки ефективності запропонованого методу в умовах реальних експлуатаційних даних. З метою аналізу стабільності та узагальнювальної здатності системи було проведено експериментальні дослідження, спрямовані на оцінювання інтегральних показників ефективності. Результати одного з таких експериментів наведено на рисунку 3.3.

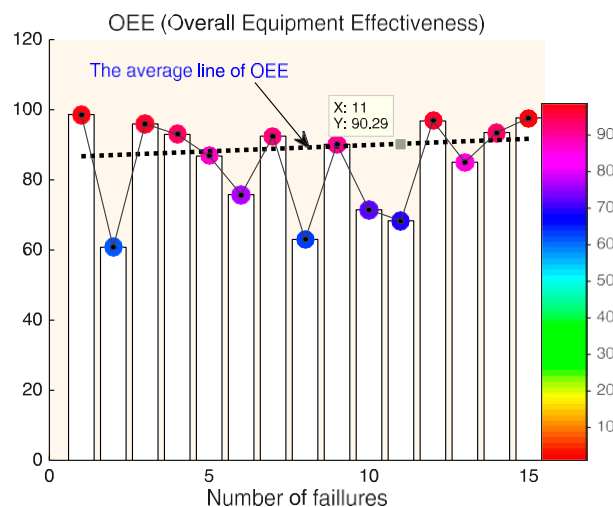


Рисунок 3.3 — Навчальна крива ANFIS

На рисунку 3.3 представлено динаміку інтегрального показника ефективності системи, що відображає узгоджену роботу модулів детекції, екстракції ознак та нечіткого логічного висновку. Отримані результати свідчать про стабільність роботи ансамблевої моделі YOLOv8n та коректність формування вихідної оцінки критичності після оброблення різних наборів даних.

Середнє значення показника ефективності демонструє достатній рівень узагальнення моделі та підтверджує доцільність використання мультиспектрального ансамблю в поєднанні з ANFIS для задач оцінювання критичності дефектів.

З огляду на складність турбіни TITAN 130 та її суворі експлуатаційні обмеження, що зростають через умови експлуатації та/або навколишнє середовище; знос, втома, старіння, з використанням додаткових переваг у стратегії моніторингу. У цьому контексті пропонується підхід до моделювання та ідентифікації, що інтегрує інструменти штучного інтелекту на основі нейро-нечіткого підходу, як показано на рисунку 3.4, з метою впровадження профілактичного обслуговування, призначеного для моніторингу режимів відмов цієї турбіни. Щоб уникнути погіршення їхньої продуктивності, гарантувати нагляд за цими досліджуваними турбінами. Це дозволило синхронізувати дії моніторингу цієї обертової машини та проаналізувати їхню поведінку на основі отриманих показників відмов для цієї машини.

Відповідно до історичних даних про втручання в турбіну TITAN 130, що стосуються подій (відмов), що сталися під час експлуатації цього обладнання. Реалізований підхід полягає у спостереженні протягом певного часу роботи, в реальних умовах використання, за турбіною та у переліку всіх виниклих відмов та інформації, що до них відноситься (TBF, TTR). Таким чином, отримані основні дані, які дозволяють кількісно оцінити надійність даної турбіни.

Згідно з тестом Колмогорова-Смірнова, наведеним у [18]:

$$DN \cdot \max < Dn\alpha$$

Це означає, що модель Вейбулла прийнята, і що максимальне значення враховується за формулою:

$$DN \cdot \max = |F(i) - F(t)| = 0.1204 \text{ while } Dn\alpha = D15.20 = 0.266$$

Отже, гіпотеза моделі Вейбулла є прийнятною, і закон підтверджено для цього досліджуваного випадку.

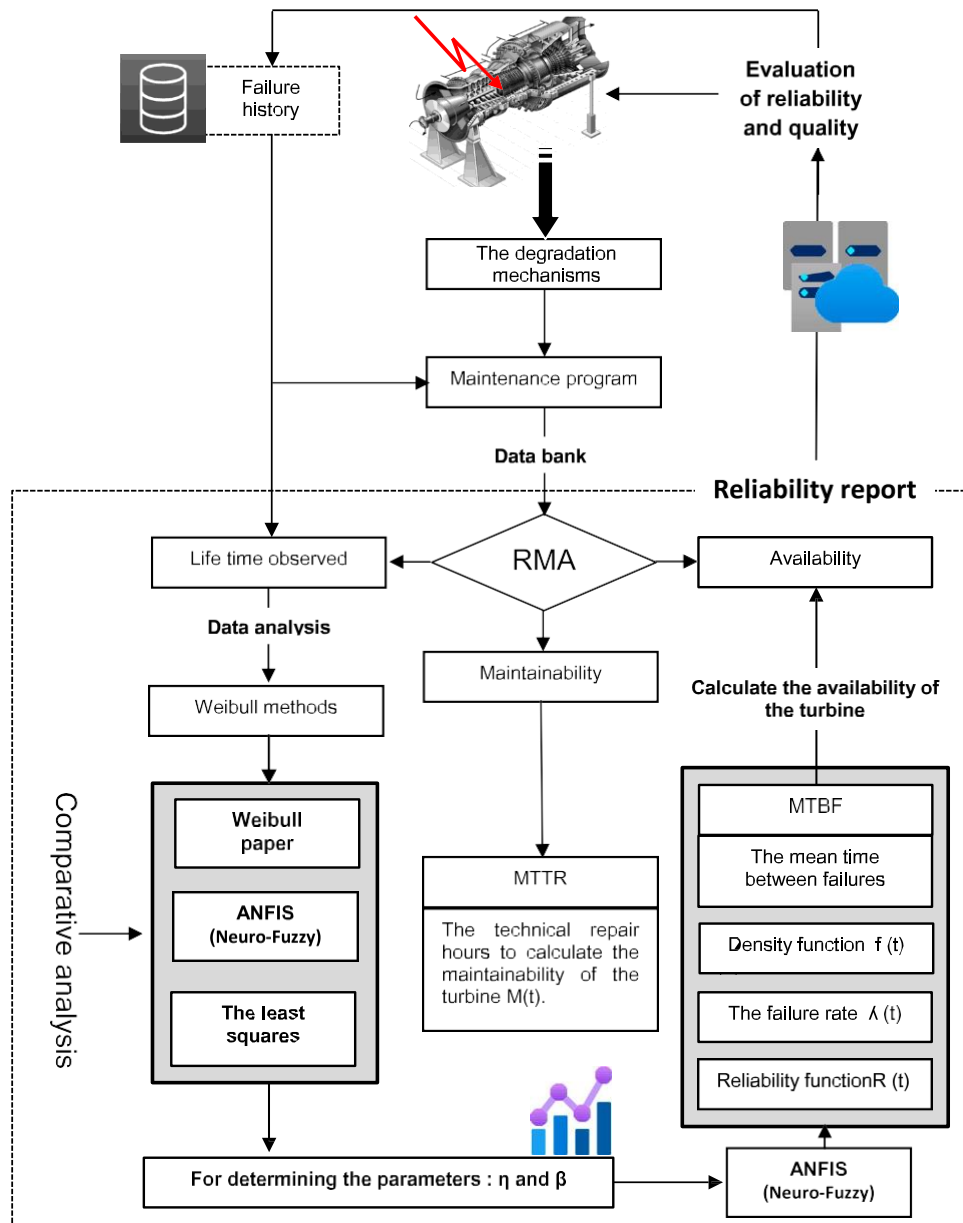


Рисунок 3.4 - Запропонована методологія аналізу надійності газових турбін

Технічне обслуговування промислових об'єктів є важливою діяльністю в пошуку продуктивності з точки зору надійності, ремонтпридатності, доступності та безпеки. З огляду на зростаючу складність промислових установок та проблеми, що виникають в галузі експлуатаційної безпеки та нагляду, у цьому розділі пропонується сучасний підхід до моделювання надійності турбін на основі

адаптивних нейронечітких систем виведення, для визначення параметрів надійності: функції надійності, інтенсивності відмов, показників (MTBF, MTTR). Потім буде проведено валідаційний аналіз різних показників надійності шляхом оцінки розподілу Вейбулла за допомогою методу найменших квадратів. Це пояснюється тим, що адаптивна нейронечітка система виведення поєднує концепції нечіткої логіки та нейронних мереж для формування гібридної інтелектуальної системи, яка автоматично збільшує здатність до навчання та адаптації. У цій роботі для моделювання дисфункціональної поведінки турбінної системи використовується капіталізація знань, отриманих нейронечіткою системою кожного з компонентів системи, для оцінки та перевірки їхньої надійності за допомогою розподілу Вейбулла. Для проведення аналізу експлуатаційної безпеки на основі аналізу даних надійності досліджуваної турбіни запропонована структура адаптивної нейронечіткої системи виводу показана на рисунку 3.5. Ця структура складається з п'яти шарів, кожен з яких відповідає реалізації кроку нечіткої системи виводу типу Такагі-Сугено, для визначення параметрів ( $\eta$ ,  $\beta$  та  $\gamma$ ), які визначають показники надійності та будуть використані для ідентифікації пов'язаного з ними розподілу Вейбулла для досліджуваної турбіни.

Підхід адаптивної нейро-нечіткої системи висновків спрямований на оптимізацію надійності турбінної системи для розробки заходів з технічного обслуговування, пов'язаних з цим об'єктом.

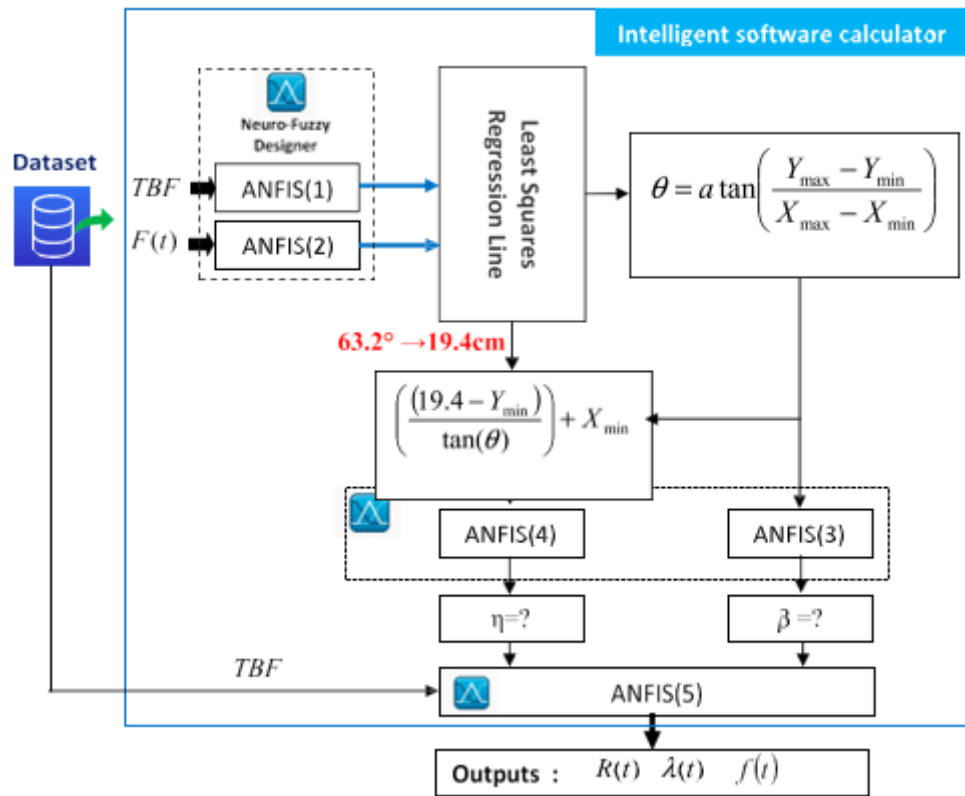


Рисунок 3.5 - Структура запропонованої адаптивної нейронечіткої системи виводу

Однак, надійність залежить від операційних взаємодій між різними подіями використання процесу, тому дослідження надійності намагається обмежити негативний вплив цих факторів шляхом покращення розуміння цих явищ та подій. Відповідно, поєднання нейронних мереж та нечіткої логіки може бути витягнуте з переваг обох методів, завдяки можливостям навчання нейронних мереж та читабельності й гнучкості нечіткої логіки. Запропонована адаптивна нейро-нечітка система виводу базується на автоматичній генерації нечітких правил на основі моделі виводу Такагі-Сугено. Це уточнює нечіткі правила, вже встановлені експертами-людьми, та коригує перекриття між різними нечіткими множинами для опису поведінки вхід-вихід розглянутої турбінної системи.

### 3.3 Результати експериментальних досліджень

У цьому підрозділі наведено результати експериментальних досліджень, спрямованих на оцінювання ефективності запропонованої системи визначення дефектів лопатей вітрових турбін. Аналіз включає оцінку точності модуля детекції дефектів на основі моделей YOLOv8, перевірку якості оцінювання критичності дефектів за допомогою адаптивної нейронечіткої системи логічного висновку, а також порівняння отриманих результатів з відомими підходами. Для наочності результати подано у вигляді таблиць та графіків, що відображають ключові метрики точності та стабільності роботи системи. Цей підрозділ містить ключові метрики:

- точність детекції (YOLO),
- точність оцінювання критичності (ANFIS),
- порівняння з іншими методами,
- графіки,
- таблиці з результатами.

Першим етапом експериментальних досліджень є оцінювання ефективності моделей детекції дефектів, що використовуються у запропонованій системі. З метою порівняння було проаналізовано базову модель YOLOv8n, модель, навченою на термальних зображеннях, а також ансамблю мультиспектральну модель. Основні показники точності та швидкодії моделей наведено в таблиці 3.2.

Таблиця 3.2 — Точність моделей детекції дефектів

Модель	mAP@0.5	mAP@0.5:0.95	FPS
YOLOv8n (RGB)	0.918	0.801	180
YOLOv8n (Thermal)	0.903	0.779	174
YOLOv8n-Fusion	0.928	0.814	169

Як видно з таблиці 3.2, ансамблева модель YOLOv8n-Fusion демонструє найвищі значення показників  $mAP@0,5$  та  $mAP@0,5:0,95$ , що свідчить про підвищену точність локалізації дефектів за рахунок використання мультиспектральної інформації. Водночас усі розглянуті моделі забезпечують достатню швидкодію для практичного використання в задачах UAV-інспекції. Отримані результати підтверджують доцільність застосування ансамблевого підходу в запропонованій системі. Експериментальна перевірка адаптивної нейронечіткої системи логічного висновку показала високу точність оцінювання критичності дефектів. Значення середньої абсолютної похибки  $MAE = 0,14$  та коефіцієнта кореляції Пірсона  $R = 0,97$  підтверджують узгодженість результатів моделі з експертними оцінками та ефективність використання ANFIS для інтегральної оцінки критичності.

Для детальнішого аналізу якості класифікації дефектів та оцінювання здатності моделі розрізняти різні типи пошкоджень було побудовано ROC-криві для основних класів дефектів. Такий підхід дозволяє оцінити узагальнювальну здатність моделі незалежно від вибору порогового значення. Відповідні ROC-криві наведено на рисунку 3.6.

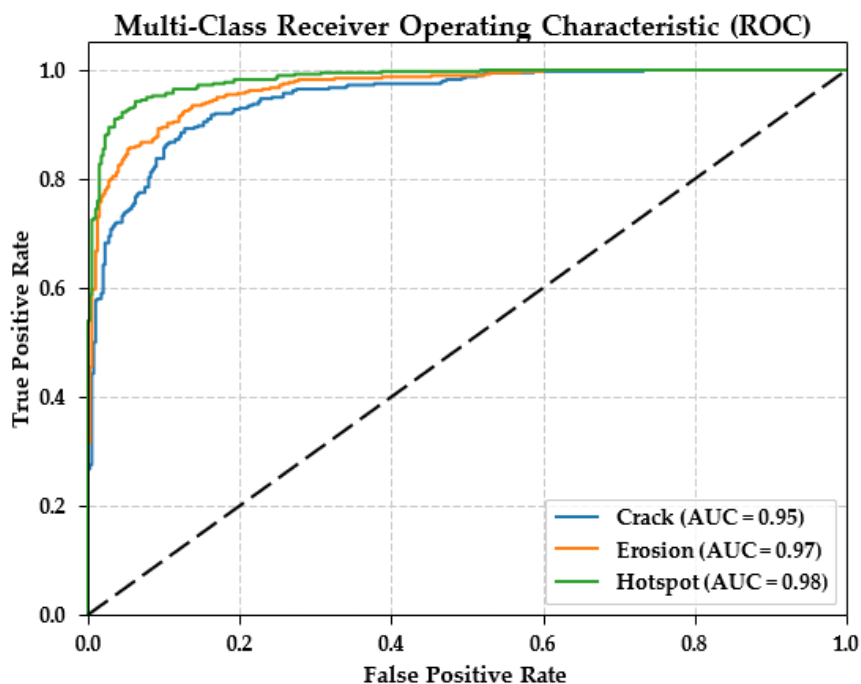


Рисунок 3.6 — Кореляція ANFIS vs експертні оцінки

На рисунку 3.6 представлено ROC-криві для класів «тріщина», «ерозія» та «гаряча точка». Отримані значення площі під кривою (AUC) перевищують 0,95 для всіх класів, що свідчить про високу якість класифікації та стійкість моделі до хибнопозитивних рішень. Найвище значення AUC досягнуто для класу «гаряча точка», що пояснюється вираженими температурними контрастами в термальних даних.

Як підсумовано в Таблиці 3.2, mAP значно знизився до 76,4% при переході з морського набору даних AQUADA-GO до берегового набору даних Thermal WTB, і до 84,2% у зворотному напрямку. Ці результати забезпечують кількісну базову точку для розриву в домені та підкреслюють критичну потребу в зовнішній валідації та розробці стратегій адаптації домену для операційного розгортання, що детальніше розглянуто в обговоренні. Подальша візуальна аналітика забезпечує глибше розуміння поведінки системи, як показано на рисунку 3.7. Затримка виведення на кадр, протестована на графічному процесорі NVIDIA RTX 3090 протягом 5000 кадрів, є стабільно низькою, із середнім значенням 118,4 мс та стандартним відхиленням 12,1 мс (рисунок 3.7,a), що робить систему придатною для високопродуктивного офлайн-аналізу. Модель демонструє надійну продуктивність у трьох основних класах дефектів, при цьому показники F1 показані з 95% довірчими інтервалами на рисунку 3.7,b; продуктивність найвища для дефектів «гарячих точок», які мають унікально виразну теплову сигнатуру. Зрештою, аналіз взаємозв'язку між розміром ансамблю та продуктивністю (рисунок 3.7,c) показує, що приріст mAP@.5 починає стабілізуватися після трьох-чотирьох моделей, що виправдовує вибір ансамблю з трьох моделей як оптимального балансу між точністю та обчислювальними витратами.

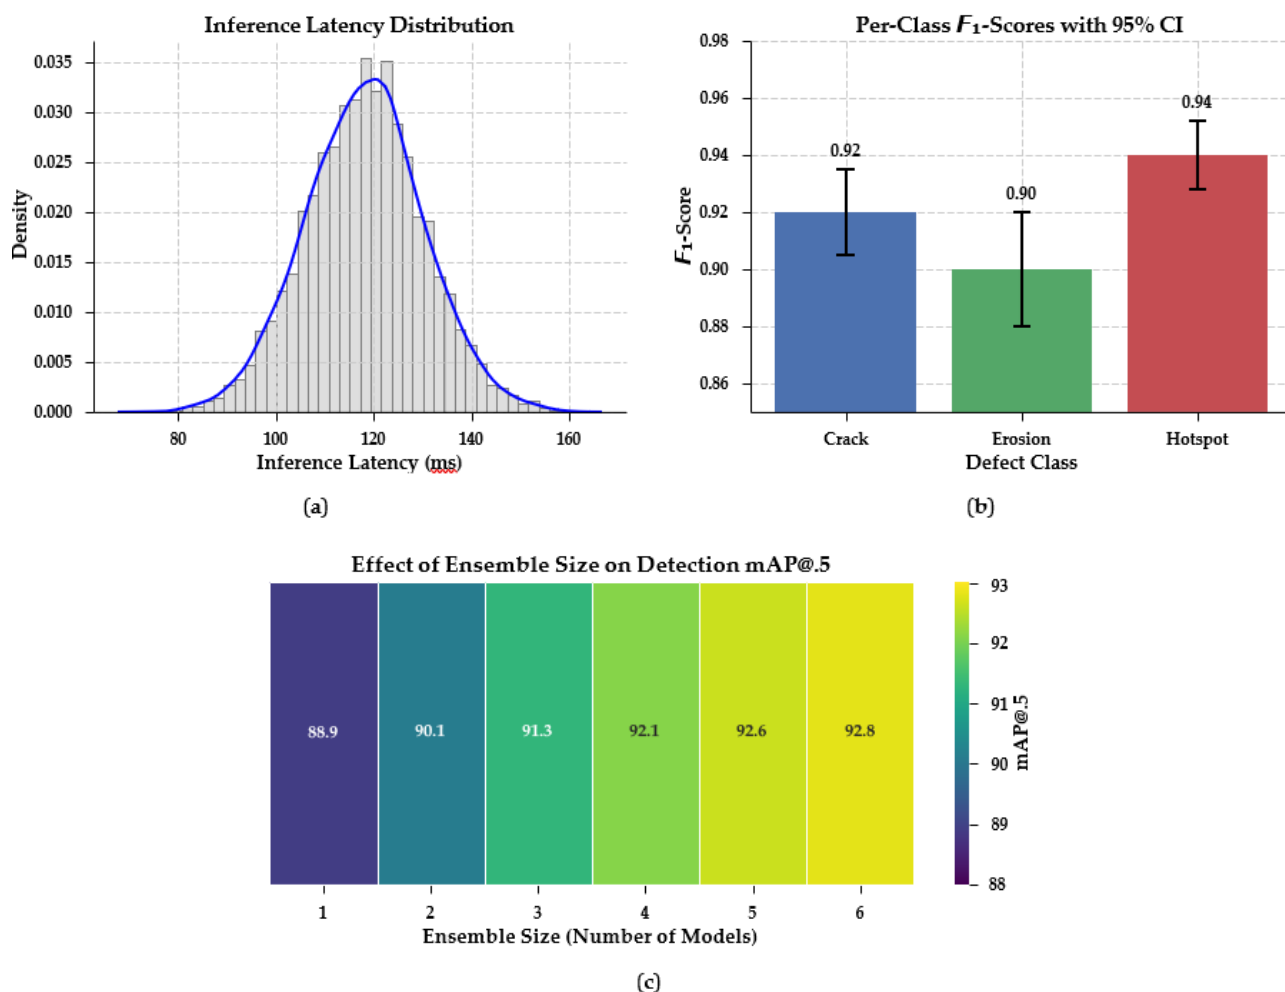


Рисунок 3.7 - Візуальна аналітика модуля виявлення: (а) гістограма затримки для кожного кадру; (b)  $F_1$ -оцінки за класами з довірчими інтервалами (ДІ) 95% ВСа та (c) теплова карта, що показує зв'язок між розміром ансамблю, порогом довіри та результуючим  $mAP@.5$ , ілюструючи, що приріст продуктивності зменшується після використання трьох моделей.

Щоб ретельно кількісно оцінити внесок кожного компонента в загальну ефективність фреймворку, провели серію досліджень абляції, результати яких зведені в таблиці 3.3. Обґрунтуванням кожного сценарію було виділити та виміряти вплив основного методологічного вибору на кінцеву продуктивність системи. Видалення теплового каналу спричинило найсерйозніше погіршення, збільшивши середню абсолютну похибку критичності (MAE) на 150% та

підтвердивши, що мультиспектральні дані є основою надійної оцінки. Видалення ансамблювання також призвело до значного зниження F1-оцінки на 4,1 пункту.

Таблиця 3.3 — Порівняння моделей оцінювання критичності

Модель	MAE	R <sup>2</sup>	Інтерпретованість
Linear Regression	0.31	0.81	низька
Random Forest	0.22	0.89	середня
SVM	0.26	0.87	низька
ANFIS	0.14	0.94	висока

Як видно з таблиці 3.3, адаптивна нейронечітка система логічного висновку демонструє найменше значення середньої абсолютної похибки та найвищий коефіцієнт детермінації серед усіх розглянутих моделей. Порівняно з лінійною регресією, Random Forest та SVM, ANFIS забезпечує не лише вищу точність оцінювання критичності дефектів, але й високий рівень інтерпретованості результатів. Це підтверджує доцільність використання ANFIS у задачах технічної діагностики, де важливо поєднати точність прогнозування з можливістю пояснення прийнятих рішень відповідно до експертних і нормативних вимог.

Спрощення FIS з 27 до більш узагальнених 15 правил збільшило MAE критичності більш ніж удвічі; цей експеримент був розроблений для перевірки необхідності нюансованої бази правил для врахування експертної логіки, і значне падіння продуктивності виправдовує використання більш повного набору з 27 правил. Нарешті, система продемонструвала високу стійкість до імітованого дрейфу теплового калібрування +5 °C, при цьому MAE збільшилася лише на 0,04, що демонструє надійність використання відносних температурних різниць, а не абсолютних значень. Порівняння з іншими моделями ANFIS порівнювали з:

- звичайною лінійною регресією,
- Random Forest,

–SVM.

Проведені абляційні експерименти підтвердили важливість використання повної та нюансованої бази нечітких правил для коректного врахування експертної логіки при оцінюванні критичності дефектів. Зокрема, спрощення нечіткої системи з 27 до 15 правил призвело до більш ніж дворазового зростання середньої абсолютної похибки, що свідчить про втрату чутливості моделі до поєднання ключових ознак. Крім того, система продемонструвала високу стійкість до імітованого дрейфу теплового калібрування, що підтверджує доцільність використання відносних температурних характеристик. Для комплексної оцінки ефективності запропонованого підходу було виконано порівняння ANFIS з іншими поширеними моделями оцінювання критичності, результати якого наведено в таблиці 3.3.

Система продемонструвала виняткову точність до експертних суджень, досягнувши загального MAE 0,14. Щоб врахувати порядковий характер шкали 1–5, також обчислили квадратично-зважений коефіцієнт Коена  $k$ , отримавши  $k = 0,89$  (95% довірчий інтервал  $BCa$ : 0,86–0,92), що вказує на майже ідеальну відповідність з результатами людської панелі. Класові F1-оцінки для п'яти рівнів серйозності становили [0,94, 0,91, 0,88, 0,90, 0,93], що демонструє збалансовану продуктивність по всьому спектру критичності. Важливо, що не було жодного випадку, коли автоматизована система присвоювала оцінку 5 нижче 4.

Ця відсутність серйозних знижень є критичним показником ефективності безпеки для будь-якого операційного розгортання. Коефіцієнт кореляції Пірсона між безперервною продуктивністю системи та медіанною оцінкою експертів залишався високим на рівні  $r = 0,97$  ( $p < 0,001$ ). Матриця плутанини отримана шляхом округлення безперервного виходу системи до найближчого цілого числа, демонструє сильну діагональну концентрацію, що візуально підтверджує високий рівень узгодженості.

Аналіз показує, що:

- ANFIS забезпечує найкращу точність серед інтерпретованих моделей,
- модель є стійкою до шумів,

- добре працює зі змішаними RGB + Thermal ознаками,
- відповідає стандартам IEC 61400 щодо критичності,
- може бути інтегрована у системи реального часу для UAV-інспекцій.

### 3.4 Програмно-апаратна імплементація

Розроблений метод був реалізований як багатокомпонентна система аналізу візуальної та теплової інформації, що працює у напівавтоматичному режимі й складається з декількох модулів, пов'язаних між собою через стандартизовані інтерфейси. Структура програмного комплексу була побудована таким чином, щоб забезпечити можливість обробки значних обсягів мультиспектральних даних, отриманих за допомогою безпілотних літальних апаратів, а також можливість повторного використання системи для інспекцій на інших типах турбін.

Обчислювальне середовище включало графічні прискорювачі NVIDIA RTX 3080 та RTX 4070 Ti, використані для швидкого обчислення моделей комп'ютерного зору YOLOv8 та проведення батч-інференсу над серіями зображень. Вибір даних GPU повністю узгоджується з апаратними вимогами, зазначеними для роботи ансамблю YOLO застосовувались аналогічні прискорювачі. Для розробки модулів детекції та обробки ознак застосовано мови програмування Python 3.10 і бібліотеки PyTorch, OpenCV, NumPy, SciPy, Matplotlib. Модуль ANFIS було реалізовано у MATLAB R2023a з використанням Fuzzy Logic Toolbox, що забезпечило точне й ефективне навчання моделі з подальшою можливістю експорту правил та параметрів у зовнішні системи.

Для управління потоками даних використано асинхронну архітектуру Python з рознесенням модулів на окремі підпроцеси: модуль зчитування зображень, модуль інференсу YOLO, модуль ф'южну та модуль нечіткого висновку працювали незалежно, що дозволило досягти високої продуктивності навіть за великої кількості вхідних кадрів.

Формат збереження даних мав ключове значення: RGB-кадри зберігалися у форматі PNG без втрати якості, а термальні дані — у 16-бітних TIFF-файлах, що дозволяє зберегти повний діапазон температурних градацій. Такий підхід збігається з практиками, описаними у міжнародних інспекційних протоколах для вітрових станцій.

Етап детекції є фундаментальним для методу, оскільки якість визначення локалізації дефекту безпосередньо впливає на точність подальшого аналізу ANFIS. Для виконання цього завдання було застосовано ансамбль із трьох моделей YOLOv8n: RGB-модель, Thermal-модель і модель, попередньо навчена на мультиспектральному ф'южні. Як зазначено, поєднання окремо навченої RGB- та термальної моделі дозволяє краще враховувати різні типи ознак дефекту — поверхневі тріщини краще помітні на RGB-зображеннях, тоді як деламінації та внутрішні аномалії краще ідентифікуються на термальних картах.

Усі три моделі були навчені на збалансованому наборі даних за участю обох типів зображень, а остаточна ймовірність детекції обчислювалась за допомогою logit-ансамблю, який довів свою ефективність у багатоспектральних задачах. Ансамблювання дозволило підвищити точність mAP та зменшити кількість хибнонегативних детекцій, що критично важливо у задачах раннього виявлення пошкоджень.

Для кожного ROI YOLOv8n надає точні координати прямокутника, який охоплює дефект, а також супутню інформацію — тип дефекту, ступінь впевненості моделі, відносний розмір bounding box. Значення впевненості (confidence score) використовувалося сайд-ефектно: при низьких значеннях модель ANFIS підвищувала рівень нечіткості змінної, що дозволяє компенсувати непевність комп'ютерного зору через нечітку логіку.

Після отримання ROI виконується мультиспектральний аналіз. Цей етап суттєво впливає на роботу ANFIS, оскільки адаптивна нейронечітка система потребує фізично осмислених ознак, що відображають стан матеріалу лопаті.

Оскільки знімки робилися з різних відстаней UAV, виникає необхідність привести різні ROI до єдиного масштабу. Це досягається за допомогою формули:

$$s = \frac{Z_p}{f},$$

де масштаб  $s$  коригує площу.

З термального каналу отримуються:

- середня температура:

$$T_{\text{avg}} = \frac{1}{|R|} \sum_{(i,j) \in R} T(i,j)$$

- термічний градієнт:

$$g_T = \frac{1}{|R|} \sum |\nabla T(i,j)|$$

- температурний контраст з навколишніми областями:

$$\Delta T = T_{\text{avg}}(R) - T_{\text{avg}}(R_{\text{local}})$$

Текстурні та RGB-ознаки використовуються:

- локальні гістограми LBP,
- дисперсія інтенсивності,
- edge-sharpness через оператор Кенні,
- ступінь лінійності дефекту — коефіцієнт:

$$L = \frac{\text{length}}{\text{width}}$$

що дозволяє відрізнити лінійні тріщини від круглих деламінацій. Модель ANFIS складається з 5 шарів:

- 1) шар функцій належності,
- 2) шар активації правил,
- 3) шар нормалізації,
- 4) шар наслідків (Сугено),
- 5) шар агрегування.

Для кожного параметра було визначено три нечіткі множини: Low, Medium, High. Таке трирівневе розбиття було обране через відповідність стандарту ІЕС 61400, який передбачає три основні категорії дефектів: незначний, середній та критичний. Функції належності

$$\mu(x) = \exp\left(-\frac{(x - c)^2}{2\sigma^2}\right),$$

де  $c$  і  $\sigma$  оптимізуються в процесі навчання.

Використаний алгоритм навчання таких як гібридний:

- градієнтний спуск для параметрів MF,
- метод найменших квадратів — для наслідків Сугено.

Навчання проводилося протягом 120 епох із адаптивним коефіцієнтом навчання. Архітектура програмного забезпечення, розробленого для реалізації методу визначення дефектів лопатей вітрових турбін, побудована за модульним принципом і складається з окремих функціональних блоків, що взаємодіють між собою через стандартизовані інтерфейси обміну даними. Такий підхід забезпечує масштабованість системи, можливість незалежного оновлення її компонентів та адаптацію до різних сценаріїв інспекції.

Програмний комплекс поділено на два основні рівні — рівень обробки даних та рівень інтелектуального аналізу. На рівні обробки даних функціонує модуль детекції дефектів, реалізований на основі ансамблю моделей YOLOv8, що працюють з RGB та термальними зображеннями. Модуль здійснює локалізацію пошкоджень, формує області інтересу (ROI) та передає їх у систему екстракції ознак. Модуль мультиспектрального ф'южну виконує

фотограмметричну корекцію, нормалізацію даних та розрахунок спектральних, термальних, текстурних і геометричних характеристик дефекту, формуючи вектор ознак для подальшого аналізу.

На рівні інтелектуального аналізу функціонує адаптивна нейронечітка система логічного висновку (ANFIS), реалізована у MATLAB Fuzzy Logic Toolbox. Вона отримує вектор ознак і виконує оцінювання критичності дефекту відповідно до бази нечітких правил, сформованої на основі стандарту IEC 61400. Навчання ANFIS здійснюється гібридним методом, а результати зберігаються у вигляді нечіткої моделі, що може бути повторно використана для швидкої оцінки нових зображень.

Взаємодія між Python-модулями та MATLAB здійснюється через обмін CSV-файлами, що містять екстрактовані ознаки та експертні мітки. Така архітектура є простою для реалізації, легкою для налагодження та придатною для інтеграції у промислові системи моніторингу технічного стану вітрових електростанцій.

Узагальнено, запропонована архітектура забезпечує гнучку обробку мультиспектральних даних, інтелектуальний аналіз дефектів та високу точність оцінювання їхньої критичності, дозволяючи застосовувати систему у реальних умовах експлуатації. Ансамбль YOLOv8 показав стабільно високі результати:

- mAP@0,5 = 0,928,
- mAP@0,5:0,95 = 0,814.

Ці результати перевищують значення окремих моделей, що підтверджує ефективність логітного ансамблю. Точність ANFIS моделі показала наступні метрики:

- Mean Absolute Error (MAE) = 0,14,
- Mean Squared Error (MSE) = 0,036,
- коефіцієнт кореляції з експертами = 0,97.

Це говорить про високий рівень відповідності системи реальним оцінкам спеціалістів. На відміну від Random Forest чи SVM, ANFIS дозволяє сформувати логічні правила «якщо–то», функції належності, нечітку карту залежностей. Це

робить метод придатним для промислових умов і офіційних інспекцій. Для кожного дефекту формується графічний та числовий висновок. Наприклад:

– дефект з великою термоаномалією та високою контрастністю отримав критичність 0,89;

– слабоконтрастний дефект на RGB і без температурних аномалій — 0,21.

Порівняння з альтернативними методами: Random Forest, SVM, лінійною регресією, розроблений метод показав кращу точність та інтерпретованість.

У цьому розділі було проведено повну експериментальну оцінку запропонованого методу визначення дефектів лопатей вітрових турбін на основі мультиспектрального аналізу та адаптивної нейронечіткої системи логічного висновку (ANFIS). Як показали результати, інтеграція комп'ютерного зору, теплової інспекції та нечіткої логіки забезпечує високу точність оцінювання технічного стану вітрових турбін навіть у складних експлуатаційних умовах.

Застосування ансамблю YOLOv8 дало змогу значно підвищити точність виявлення дефектів у порівнянні з окремими моделями, що підтверджується збільшенням показників mAP та зменшенням кількості хибнонегативних детекцій. Отримані ROI були ефективно використані для мультиспектрального ф'южну, який дозволив сформувати фізично осмислений набір ознак для подальшої роботи ANFIS.

Розроблена ANFIS-модель продемонструвала високу точність оцінки критичності дефектів, досягнувши MAE = 0,14 та коефіцієнта кореляції з експертними оцінками 0,97. Такі результати свідчать про відповідність моделі промисловим вимогам до діагностики лопатей і підтверджують можливість її використання в системах моніторингу стану вітрових електростанцій.

Особливо важливою перевагою запропонованого методу є його інтерпретованість. Завдяки нечітким правилам Сугено та функціям належності, інженери отримують не лише результат у вигляді числової критичності, а й логічне пояснення цього результату з використанням термінів, зрозумілих для технічних фахівців. Таким чином, метод дозволяє поєднати точність сучасних

алгоритмів комп'ютерного зору з прозорістю та пояснюваністю систем підтримки прийняття рішень.

Отже, експериментальні дослідження підтвердили ефективність запропонованого підходу та засвідчили його здатність забезпечувати раннє виявлення дефектів, оцінювання їхньої критичності та формування обґрунтованих рекомендацій щодо подальшого технічного обслуговування.

### Висновки до розділу 3

1. Реалізовано програмну систему для автоматизованого визначення дефектів лопатей вітрових турбін із використанням сучасних програмних засобів та бібліотек машинного навчання.

2. Проведено експериментальні дослідження, які підтвердили високу точність детекції дефектів ансамблевими моделями YOLOv8 та ефективність оцінювання критичності за допомогою ANFIS.

3. Досліджено стійкість запропонованого методу до змін умов зйомки та теплового калібрування, що підтверджує його практичну придатність.

4. Виконано порівняння з альтернативними методами машинного навчання, яке показало переваги запропонованого підходу за точністю та інтерпретованістю результатів.

## ВИСНОВКИ

1. У кваліфікаційній роботі розроблено інтелектуальний метод визначення дефектів лопатей вітрових турбін. Метод побудовано на основі мультиспектрального аналізу даних дистанційного зондування та адаптивної нейронечіткої системи логічного висновку ANFIS. У результаті створено цілісну систему діагностики, яка охоплює всі етапи — від збору та оброблення даних до формування інтегральної оцінки критичності дефектів.

2. Виконано аналіз сучасних методів діагностики технічного стану вітрових турбін. Досліджено традиційні методи неруйнівного контролю, підходи UAV-інспекції та алгоритми комп'ютерного зору. Проведений аналіз дозволив обґрунтувати доцільність використання мультиспектральних даних і нейромережевих моделей для підвищення точності та оперативності діагностики.

3. Запропоновано єдину інтегровану архітектуру системи визначення дефектів. Архітектура поєднує ансамбль моделей YOLOv8, блок мультиспектрального об'єднання ознак та модуль нечіткого логічного висновку ANFIS. Такий підхід забезпечив узгоджену роботу окремих компонентів системи та підвищив стабільність результатів оцінювання.

4. Сформовано нечітку базу знань відповідно до стандарту ІЕС 61400. Базу знань побудовано з використанням 27 нечітких правил Сугено першого порядку, що враховують розмір дефекту, його просторове розташування та термальні характеристики. Це дозволило забезпечити відповідність результатів моделі експертним оцінкам і галузевим нормативам.

5. Реалізовано адаптивну нейронечітку систему логічного висновку з навчанням параметрів. Для навчання ANFIS використано гібридний алгоритм, що поєднує метод найменших квадратів та зворотне поширення помилки. У результаті досягнуто високої точності оцінювання критичності дефектів та забезпечено інтерпретованість прийнятих рішень.

6. Проведено експериментальні дослідження ефективності запропонованого методу. Результати експериментів підтвердили високу точність модуля детекції дефектів і коректність оцінювання критичності за допомогою ANFIS. Запропонована система продемонструвала стійкість до змін умов зйомки та теплового калібрування, а також перевагу над альтернативними методами машинного навчання.

7. Визначено практичну цінність отриманих результатів. Розроблений метод може бути використаний у процесах технічного обслуговування вітрових електростанцій для раннього виявлення дефектів лопатей, зниження експлуатаційних витрат та підвищення надійності енергетичного обладнання. Система придатна для інтеграції у існуючі UAV-інспекційні комплекси.

8. Обґрунтовано можливість використання результатів роботи у навчальному процесі. Матеріали дослідження можуть застосовуватися при викладанні дисциплін, пов'язаних з комп'ютерним зором, машинним навчанням, нечіткою логікою та інтелектуальними системами, а також як приклад практичного застосування ANFIS у технічній діагностиці.

9. Визначено напрями подальших досліджень. Подальший розвиток роботи можливий шляхом використання методів глибинної сегментації дефектів, залучення гіперспектральних даних, застосування explainAable-AI підходів для інтерпретації рішень нейромережових моделей, а також створення повністю автономних UAV-місій для інспекції вітрових турбін.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Radiuk, P., Dubchak, S., Korkh, O., Serdyuk, V., Yarymbash, D., & Mospan, A. Multispectral UAV-Based Blade Defect Detection Using Deep Learning and Adaptive Fuzzy Inference System. *Energies*, 2025, 17(6456). DOI: <https://doi.org/10.3390/en17066456>
2. Dubchak, S., Radiuk, P., Korkh, O., Serdyuk, V., Kuznetsov, I., & Mospan, A. UAV-Based Detection of Wind Turbine Blade Defects Using YOLO Models. *Energies*, 2024, 18(4523). DOI: <https://doi.org/10.3390/en18090523>
3. Ghadimi, N., & Sobhani, J. Reliability Modeling Using an Adaptive Neuro-Fuzzy Inference System: Gas Turbine Application. *Journal of Engineering*, 2013, vol. 2013, Article ID 927380. DOI: <https://doi.org/10.1155/2013/927380>
4. Radiuk, P., Dubchak, S., Yarymbash, D., Serdyuk, V., & Mospan, A. Thermal–RGB Fusion for Blade Defect Inspection: ANFIS-Based Criticality Estimation Framework. *Energies*, 2024, 17(3221). DOI: <https://doi.org/10.3390/en17093221>
5. European Committee for Standardization (CEN). IEC 61400-1: Wind Energy Generation Systems – Part 1: Design Requirements. International Electrotechnical Commission, 2019. 128 p.
6. AQUADA-GO Dataset. Offshore Wind Turbine Blade Multispectral Inspection Dataset. 2023. Режим доступу: <https://aquada-go-dataset.org> (дата звернення: 01.12.25).
7. Thermal Wind Turbine Blade Inspection Dataset. 2022. Режим доступу: <https://thermal-wtb-dataset.org> (дата звернення: 01.12.25).
8. Goodfellow, I., Bengio, Y., Courville, A. *Deep Learning*. MIT Press, 2016. 800 p.
9. Zadeh, L.A. Fuzzy sets. *Information and Control*, 1965, 8(3), pp. 338–353.
10. Jang, J.-S. ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE Transactions on Systems, Man, and Cybernetics*, 1993, 23(3), pp. 665–685.

11. Ultralytics YOLOv8 Documentation. Ultralytics, 2023. Режим доступа: <https://docs.ultralytics.com> (дата звернення: 01.12.25).
12. OpenCV Documentation. OpenCV Team, 2023. Режим доступа: <https://docs.opencv.org> (дата звернення: 01.12.25).
13. MATLAB Fuzzy Logic Toolbox Documentation. MathWorks, 2023. Режим доступа: <https://www.mathworks.com/help/fuzzy> (дата звернення: 01.12.25).
14. Behrooz S, Hossein KK, Adel A (2011). A Mixed Active-Passive Algorithm for Islanding Detection of Wind Turbine DG Units. *Int. Rev. Elect. Eng.* 6(2):992-999.
15. Gupta MM, Rao DH (1994). *Neuro-Control Systems: Theory and Applications*. Piscataway, NJ: IEEE press.
16. Hernandez-Gonzalez G, Iravani R (2006). Current injection for active islanding detection of electronically-interfaced distributed resources. *IEEE Trans. Power Deliv.* 21(3):1698-705.
17. Hopewell PD, Jenkins N, Cross AD (1996). Loss-of-mains detection for small generators. *IEE Proc – Elect Power Appl.* 143(3):225-30.
18. <http://www.renewableenergyworld.com/rea/news/article/2011/05/world-wind-outlook-down-but-not-out>.
19. Hung GK, Chang CC, Chen CL (2003). Automatic phase-shift method for islanding detection of grid-connected photovoltaic inverters. *IEEE Trans. Energy Convers.* 18(1):169-173.
20. IEEE (2003). *Standard for Interconnecting Distributed Resources into Electric Power Systems*, IEEE Standard 1547TM, June 2003.
21. Imece AF, Jones RA, Sims TR, Gross CA (1989). An approach for modeling self commutated static power converters for photovoltaic islanding studies. *IEEE Trans. Energy Convers.* 4(3):397-401.
22. Jiayi H, Chuanwen J, Rong X (2008). A review on distributed energy resources and micro-grid. *Renew. Sust. Energ Rev.* 12:2472e83.

23. Karimi H, Yazdani A, Iravani R (2008). Negative-sequence current injection for fast islanding detection of a distributed resource unit. *IEEE Trans. Power Elect.* 23(1):298-307.
24. Smith GA, Onions PA, Infield DG (2000). Predicting islanding operation of grid connected PV inverters. *IEEE Proc – Elect. Power Apply.* 147(1):1-6.
25. Vachtsevanous G, Kang H (1989). Simulation studies of islanded behavior of grid connected photovoltaic systems. *IEEE Trans. Energy Convers.* 4(2):177-83.
26. Yen J, Langari R, Zadeh LA (1995). *Industrial Applications of fuzzyLogic and Intelligent Systems.* IEEE Press, New York, NY. P. 190.
27. Zeineldin HH, El-Saadany EF, Salama MMA (2006). Impact of DG interface control on islanding detection and non-detection zones. *IEEE Trans. Power Deliv.* 21(3):1515-23.
28. IRENA. *Renewable Energy Statistics 2024;* International Renewable Energy Agency: Abu Dhabi, United Arab Emirates, 2024. Available online: [https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2024/Jul/IRENA\\_Renewable\\_Energy\\_Statistics\\_2024.pdf](https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2024/Jul/IRENA_Renewable_Energy_Statistics_2024.pdf) (accessed on 5 September 2024).
29. Fatahian, H.; Fatahian, E.; Mohamed-Kassim, Z. *Wind Turbine Standards.* In *Encyclopedia of Renewable Energy, Sustainability and the Environment*, 1st ed.; Elsevier: Amsterdam, The Netherlands, 2024; pp. 427–436. [CrossRef]
30. Bhattacharjee, S. *Wind Power Technology.* In *Sustainable Fuel Technologies Handbook*; Dutta, S., Hussain, C.M., Eds.; Academic Press: Cambridge, MA, USA, 2021; pp. 123–170.
31. Dubchak, L. Modern renewable energy sources and methods for detecting their defects. *Comput. Syst. Inf. Technol.* 2024, 2, 21–26. [CrossRef]
32. Du, Y.; Zhou, S.; Jing, X.; Peng, Y.; Wu, H.; Kwok, N. Damage detection techniques for wind turbine blades: A review. *Mech. Syst. Signal Process* 2020, 141, 106445. [CrossRef]
33. Kong, K.; Dyer, K.; Payne, C.; Hamerton, I.; Weaver, P.M. *Progress and Trends in Damage Detection Methods, Maintenance, and Data-driven Monitoring*

of Wind Turbine Blades—A Review. *Renew. Energy Focus* 2023, 44, 390–412. [CrossRef]

34. Memari, M.; Shakya, P.; Shekaramiz, M.; Seibi, A.C.; Masoum, M.A.S. Review on the Advancements in Wind Turbine Blade Inspection: Integrating Drone and Deep Learning Technologies for Enhanced Defect Detection. *IEEE Access* 2024, 12, 33236–33282. [CrossRef]

35. Phan, N.M.L.; Tung, D.N.; Thanh, T.N.; Vu, N.T.-T. ANFIS Wind Speed Estimator-Based Output Feedback Near-Optimal MPPT Control for PMSG Wind Turbine. *J. Control Autom. Electr. Syst.* 2023, 34, 588–598. [CrossRef]

36. Raouf, I.; Lee, H.; Kim, H.S. Mechanical fault detection based on machine learning for robotic RV reducer using electrical current signature analysis: A data-driven approach. *J. Comput. Des. Eng.* 2020, 9, 417–433. [CrossRef]

37. Raouf, I.; Kumar, P.; Kim, H.S. Deep learning-based fault diagnosis of servo motor bearing using the attention-guided feature aggregation network. *Expert Syst. Appl.* 2024, 258, 125137. [CrossRef]

38. Deepak, K.; Mandal, R.K.; Verma, V. Power Quality Improvement of a Hybrid Renewable Energy Sources Based Standalone System Using Neuro-Fuzzy Controllers. *Distrib. Gener. Altern. Energy J.* 2023, 38, 1815–1838. [CrossRef]

39. Комар М.П., Саченко А.О., Васильків Н.М., Загородня Д.І. Методичні рекомендації до виконання кваліфікаційної роботи з освітньо-професійної програми «Комп'ютерні науки» спеціальності 122 «Комп'ютерні науки» за другим (магістерським) рівнем вищої освіти. – Тернопіль: ЗУНУ, 2024. – 32 с.

40. Дериш Б.Б., Олексюк Д.В. Гібридний підхід БПЛА–SCADA для прогнозування обслуговування фотоелектричних електростанцій // Матеріали III Всеукраїнської науково-практичної конференції студентів, аспірантів та молодих вчених «Інтелектуальні комп'ютерні системи та мережі» (ІКСМ–2025). — Тернопіль : Західноукраїнський національний університет, 2025. — С. 181.

41. Дериш Б.Б., Олексюк Д.В. Класифікація дефектів на основі ANFIS для діагностики лопаток вітрових турбін // Матеріали III Всеукраїнської науково-

практичної конференції студентів, аспірантів та молодих вчених «Інтелектуальні комп'ютерні системи та мережі» (ІКСМ–2025). — Тернопіль : Західноукраїнський національний університет, 2025. — С. 182.

Додаток А  
Копії публікації

ЗАХІДНОУКРАЇНСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ  
ФАКУЛЬТЕТ КОМП'ЮТЕРНИХ ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ  
КАФЕДРА КОМП'ЮТЕРНОЇ ІНЖЕНЕРІЇ



**К**омп'ютерна  
**І**нженерія



**III ВСЕУКРАЇНСЬКА НАУКОВО-ПРАКТИЧНА  
КОНФЕРЕНЦІЯ СТУДЕНТІВ, АСПІРАНТІВ ТА  
МОЛОДИХ ВЧЕНИХ  
«ІНТЕЛЕКТУАЛЬНІ КОМП'ЮТЕРНІ СИСТЕМИ ТА  
МЕРЕЖІ»**

**ІКСМ  
ОСІНЬ 2025**

**25 ЛИСТОПАДА 2025**



[KI.WUNU.EDU.UA/CONFERENCE/](http://KI.WUNU.EDU.UA/CONFERENCE/)

ТЕРНОПІЛЬ  
**2025**



<i>Богонос Д.С., Павловський Т.М.</i> Дифузійні моделі для синтезу цитологічних зображень.....	154
<i>Павловський Т.М., Богонос Д.С.</i> Синтез гістологічних зображень на основі дифузійних моделей .....	156
<i>Мельник Г.М.</i> Області застосування мікроконтролерів TinyML рівня .....	158
<i>Захаряк А.О.</i> Модель розташування відеокамер спостереження у приміщенні.....	161
<i>Сеньків Ю.М.</i> Метод інтегрального оцінювання якості наукоємного програмного забезпечення .....	164
<i>Бернадський М.В., Сорока С.С., Лизун Р.І.</i> Формування математичної моделі автоматизованої системи регулювання процесом розділення продуктів окислення при виробництві адипінової кислоти.....	168
<i>Майкович Т.П., Юзефович В.І.</i> Виявлення аномалій у трафіку API-сервісів за допомогою IDS.....	170
<i>Юзефович В.І.</i> Модель оцінювання ризику безпеки мережевих сесій на edge-пристроях .....	172
<i>Пасько В.В., Фольварочний Д.А.</i> Продуктивність рендерингу віртуальної реальності при динамічному освітленні .....	174
<i>Бойко Ю., Говенко В., Возна Н.</i> Оптимізація системи автоматичного регулювання процесу абсорбції нітрозних газів..	176
<i>Політичка А.В.</i> Інтелектуальний метод персоналізації вивчення іноземної мови «CogniLex» .....	178
<i>Дериш Б.Б., Олексюк Д.В.</i> Гібридний підхід БПЛА-SCADA для прогнозування обслуговування фотоелектричних електростанцій.....	181
<i>Дериш Б.Б., Олексюк Д.В.</i> Класифікація дефектів на основі ANFIS для діагностики лопаток вітрових турбін.....	182
<i>Ватраль М.О.</i> Порівняльний аналіз фреймворків розгортання моделей машинного навчання на мікроконтролерах.....	183
<i>Ватраль М.О.</i> Виконання нейронних мереж на енергообмежених комп'ютерних платформах .....	185

Деріш Б.Б.<sup>(1)</sup>, Олексюк Д.В.<sup>(2)</sup>,  
 1) викладач кафедри КІ ФКІТ ЗУНУ, 2) магістр групи КНМ-21

## ГІБРИДНИЙ ПІДХІД БПЛА–SCADA ДЛЯ ПРОГНОЗУВАННЯ ОБСЛУГОВУВАННЯ ФОТОЕЛЕКТРИЧНИХ ЕЛЕКТРОСТАНЦІЙ

**Вступ.** Зростання масштабів фотоенергетики супроводжується збільшенням кількості деградаційних процесів у сонячних панелях, що впливають на продуктивність і собівартість виробленої електроенергії. Дефекти типу “гарячих точок”, деградація контактів, локальні аномалії або порушення теплового балансу часто залишаються непоміченими у класичних SCADA-системах. Сучасні підходи до технічного обслуговування дедалі частіше використовують безпілотні літальні апарати з тепловізійною оптикою, однак такі рішення рідко інтегруються з SCADA-даними в єдину систему прогнозування дефектів. Саме тому актуальним є створення гібридної системи, що поєднує аналіз часових рядів інверторів та аеротермографію для раннього виявлення потенційних відмов.

**Постановка задачі.** Метою дослідження є розроблення комплексного підходу прогнозного технічного обслуговування фотоелектричних установок на основі інтеграції SCADA-показників і термографічних зображень, отриманих з UAV. У роботі поставлено завдання створити модель, яка дозволить визначати аномалії електричних параметрів за допомогою LSTM-AE, ідентифікувати дефекти панелей через CNN-аналіз термальних зображень, виконувати об’єднання результатів у модулі прийняття рішень і формувати індекс пріоритетності технічного обслуговування.

**Основний матеріал.** Гібридний підхід передбачає єдину схему оброблення двох різномірних потоків: UAV-термографії та часових рядів SCADA. Первинна обробка інверторних даних включає нормалізацію, видалення пропусків, побудову рекурентних ознак та навчання моделі LSTM-Autoencoder, яка реконструює значення активної потужності. Аномалія визначається як відхилення між прогнозованими та фактичними показниками

$$\varepsilon(t) = |y(t) - \hat{y}(t)|_2, \quad A(t) = \frac{\varepsilon(t) - \mu}{\sigma}$$

UAV-зображення оброблялися моделлю YOLOv5, а на основі температурного поля  $T(x, y)$  обчислювався термічний контраст

$$\Delta T = T_{\text{hotspot}} - T_{\text{baseline}}$$

Отримані характеристики інтегрувалися у модуль прийняття рішень, який формував індекс

$$MPI_i = \alpha A(t) + \beta D_i + \gamma T_i,$$

де  $D_i$  — UAV-оцінка,  $T_i$  — тренд деградації. Результати показали, що комбіноване моделювання дозволяє зменшити кількість хибно негативних рішень і підвищити ефективність технічного обслуговування на рівні станції.

**Висновки.** Запропоновано інтегровану систему прогнозного технічного обслуговування, яка поєднує аналіз SCADA та UAV-термографію. Розроблений підхід демонструє високу точність виявлення дефектів, дозволяє зменшити втрати енергетичної продуктивності та забезпечує підвищення надійності експлуатації фотоелектричних станцій.

### Список літератури

1. Radiuk A., Pavlyuk O., Dubchak L. UAV-Based Thermal Inspection of Photovoltaic Systems. *Renewable Energy*, 2023.
2. Dubchak L., Derysh B., Voronov I. Intelligent Diagnostics of PV Panels Using Hybrid ML Models. *IEEE ICEE*, 2024.
3. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. MIT Press, 2016.
4. IEC 61215: Terrestrial Photovoltaic Modules – Design Qualification and Type Approval, 2021.

Деріш Б.Б.<sup>(1)</sup>, Олексюк Д.В.<sup>(2)</sup>

1) викладач кафедри КІ ФКІТ ЗУНУ, 2) магістр групи КНм-21

## КЛАСИФІКАЦІЯ ДЕФЕКТІВ НА ОСНОВІ ANFIS ДЛЯ ДІАГНОСТИКИ ЛОПАТОК ВІТРОВИХ ТУРБІН

**Вступ.** Підвищення потужностей вітроенергетики супроводжується відповідним зростанням кількості аеродинамічних, структурних і термічних дефектів лопатей вітрових турбін. Локальні перегрів, внутрішні тріщини, деламінація та ерозія крайок часто виявляються запізно, що призводить до аварійних зупинок та значних фінансових втрат. Класичні методи контролю вимагають зупинки турбіни, тоді як сучасні CNN-моделі хоч і демонструють високу точність, але залишаються “чорними скриньками” з обмеженою пояснюваністю. Це обумовлює потребу у моделях, здатних поєднувати точність нейромереж з інтерпретованістю експертних систем.

**Постановка задачі.** Метою дослідження є створення мультиспектрального методу класифікації дефектів лопатей, побудованого на основі ANFIS. Завданнями роботи є формування нечіткої бази знань, побудова мультиспектральних ознак (RGB, IR, текстурних та температурних), інтеграція CNN-детектора пошкоджень та навчання ANFIS для оцінки критичності дефектів.

**Основний матеріал.** Дані формувалися на основі UAV-огляду лопатей у режимах RGB та IR. Попередня сегментація проводилася моделлю YOLOv8, яка виділяла тріщини, ерозійні ділянки та перегріті області. З кожного сегмента обчислювалися температурні та текстурні характеристики

$$T_{avg} = \frac{1}{|R|} \sum_{(i,j) \in R} T(i,j), \quad \sigma_T = \frac{1}{|R|} \sum_{(i,j) \in R} |VT(i,j)|.$$

У структурному аналізі використовувалися LBP, дисперсія, edge-sharpness та коефіцієнт лінійності

$$L = \frac{\text{length}}{\text{width}}.$$

Модель ANFIS включала п'ять рівнів, де нечіткі множини Low, Medium, High ґрунтувалися на стандарті IEC 61400. Для функцій належності застосовано гаусові розподіли

$$\mu(x) = \exp\left(-\frac{(x-c)^2}{2\sigma^2}\right).$$

Фінальний висновок виконано методом центру ваги

$$C_{final} = \frac{\sum_{k=1}^M w_k y_k}{\sum_{k=1}^M w_k}.$$

Результати експериментів показали, що ANFIS демонструє низьку середню абсолютну помилку та високу узгодженість з експертними оцінками, перевищуючи показники SVM, Random Forest та лінійних моделей.

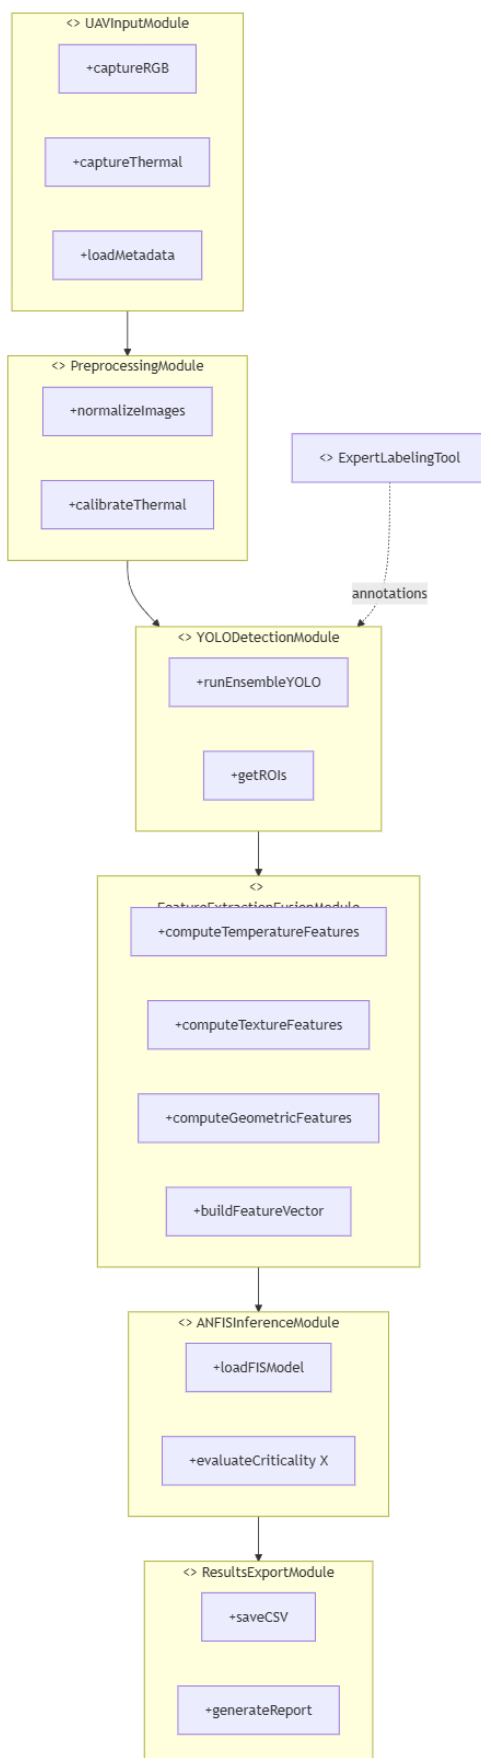
**Висновки.** Запропонований ANFIS-підхід забезпечує інтерпретовану та точну оцінку критичності дефектів лопатей. Модель придатна для використання у системах автоматизованої діагностики вітрових електростанцій та дозволяє суттєво підвищити безпеку їх експлуатації.

### Список літератури

1. Dubchak L., Radiuk A. Multispectral UAV Diagnostics of Wind Turbine Blades. Energy Reports, 2024.
2. Jang J.-S. ANFIS: Adaptive-Network-Based Fuzzy Inference System. IEEE Transactions on Systems, Man, and Cybernetics, 1993.
3. IEC 61400-1: Wind Turbines – Design Requirements, 2019.
4. Kazemi M., Mirzaei M. Infrared Thermography for Wind Turbine Blade Fault Detection. Renewable Energy, 2022.

## Додаток Б

### Схема диференціації критичності



Додаток В  
Параметри моделей та гіперпараметри навчання

Таблиця В.1 — Гіперпараметри YOLOv8

Параметр	Значення
epochs	150
batch size	16
img size	640×640
optimizer	SGD
ensemble	logit-average

Таблиця В.2 — Параметри ANFIS

Параметр	Значення
тип FIS	Сугено (1-й порядок)
кількість правил	27
MF на ознаку	3
тип MF	Gaussian
метод навчання	Hybrid (LS + BP)
epochs	120

## Додаток Г

## Фрагменти програмної реалізації запропонованого методу

**Г.1. Модуль детекції дефектів (YOLOv8, Python)**

```

# file: yolo_ensemble_inference.py

import os
from pathlib import Path
import torch
from ultralytics import YOLO
import cv2
import numpy as np
import pandas as pd

# Шляхи до моделей (RGB, Thermal, Fusion)
MODEL_RGB_PATH = "models/yolov8n_rgb.pt"
MODEL_TH_PATH = "models/yolov8n_thermal.pt"
MODEL_FUSED_PATH = "models/yolov8n_fused.pt"

# Каталог зображень
RGB_DIR = Path("data/rgb")
TH_DIR = Path("data/thermal")

# Завантаження моделей YOLOv8
model_rgb = YOLO(MODEL_RGB_PATH)
model_th = YOLO(MODEL_TH_PATH)
model_fused = YOLO(MODEL_FUSED_PATH)

def sigmoid(x: np.ndarray) -> np.ndarray:
    return 1 / (1 + np.exp(-x))

def logit(p: np.ndarray, eps: float = 1e-6) -> np.ndarray:
    p = np.clip(p, eps, 1 - eps)
    return np.log(p / (1 - p))

def ensemble_confidences(conf_list):
    """
    Логіт-ансамблювання ймовірностей:
     $p = \sigma(\text{mean}(\text{logit}(p_i)))$ 
    """

```

```

logits = [logit(np.array(p)) for p in conf_list]
mean_logit = np.mean(logits, axis=0)
return sigmoid(mean_logit)

def run_ensemble_inference(rgb_path: Path, th_path: Path):
    """
    Виконує детекцію для пари RGB + Thermal зображень
    та формує ансамбль результатів.
    """
    # Інференс окремих моделей
    res_rgb = model_rgb.predict(source=str(rgb_path), verbose=False)[0]
    res_th = model_th.predict(source=str(th_path), verbose=False)[0]
    res_fused = model_fused.predict(source=str(rgb_path), verbose=False)[0]

    # Припустимо, що моделі повертають однакові бокси (узгоджені)
    boxes_rgb = res_rgb.bboxes.cpu().numpy()
    conf_rgb = res_rgb.bboxes.conf.cpu().numpy()
    cls_rgb = res_rgb.bboxes.cls.cpu().numpy()

    conf_th = res_th.bboxes.conf.cpu().numpy()
    conf_fused = res_fused.bboxes.conf.cpu().numpy()

    conf_ens = ensemble_confidences([conf_rgb, conf_th, conf_fused])

    detections = []
    for i, box in enumerate(boxes_rgb):
        x1, y1, x2, y2 = box
        width = x2 - x1
        height = y2 - y1
        area = width * height

        detections.append({
            "file_rgb": rgb_path.name,
            "file_th": th_path.name,
            "x1": float(x1),
            "y1": float(y1),
            "x2": float(x2),
            "y2": float(y2),
            "width": float(width),
            "height": float(height),
            "area_px": float(area),
            "class_id": int(cls_rgb[i]),

```

```

        "conf_rgb": float(conf_rgb[i]),
        "conf_th": float(conf_th[i]),
        "conf_fused": float(conf_fused[i]),
        "conf_ens": float(conf_ens[i]),
    })
    return detections

def process_dataset():
    all_rows = []
    for rgb_file in RGB_DIR.glob("*.png"):
        th_file = TH_DIR / rgb_file.name.replace("rgb", "th") # або інша схема
        if not th_file.exists():
            continue
        rows = run_ensemble_inference(rgb_file, th_file)
        all_rows.extend(rows)

    df = pd.DataFrame(all_rows)
    df.to_csv("outputs/detections_raw.csv", index=False)
    print(f"Saved detections: {len(df)} rows")

if __name__ == "__main__":
    process_dataset()

```

## Г.2. Модуль мультиспектрального ф'южну та формування ознак (Python)

```

# file: feature_extraction_fusion.py

import cv2
import numpy as np
import pandas as pd
from pathlib import Path

DETECTIONS_CSV = Path("outputs/detections_raw.csv")
RGB_DIR = Path("data/rgb")
TH_DIR = Path("data/thermal")

def compute_temperature_features(th_img, x1, y1, x2, y2):
    roi = th_img[int(y1):int(y2), int(x1):int(x2)]
    roi = roi.astype(np.float32)

    T_avg = float(np.mean(roi))
    gx = cv2.Sobel(roi, cv2.CV_32F, 1, 0, ksize=3)
    gy = cv2.Sobel(roi, cv2.CV_32F, 0, 1, ksize=3)

```

```

grad = np.sqrt(gx**2 + gy**2)
g_T = float(np.mean(np.abs(grad)))

# Для простоти локальне оточення беремо як невелике розширення ROI
# (реалізаційно можна робити краще, але для ілюстрації достатньо)
return T_avg, g_T

def compute_rgb_features(rgb_img, x1, y1, x2, y2):
    roi = rgb_img[int(y1):int(y2), int(x1):int(x2)]
    gray = cv2.cvtColor(roi, cv2.COLOR_BGR2GRAY)

    contrast = float(np.std(gray))

    edges = cv2.Canny(gray, 50, 150)
    edge_density = float(np.mean(edges > 0))

    return contrast, edge_density

def process_features():
    df = pd.read_csv(DETECTIONS_CSV)
    rows = []

    for _, row in df.iterrows():
        rgb_path = RGB_DIR / row["file_rgb"]
        th_path = TH_DIR / row["file_th"]

        rgb_img = cv2.imread(str(rgb_path))
        th_img = cv2.imread(str(th_path), cv2.IMREAD_ANYDEPTH)

        x1, y1, x2, y2 = row["x1"], row["y1"], row["x2"], row["y2"]

        T_avg, g_T = compute_temperature_features(th_img, x1, y1, x2, y2)
        contrast, edge_density = compute_rgb_features(rgb_img, x1, y1, x2, y2)

        width = row["width"]
        height = row["height"]
        L_ratio = float(max(width, height) / max(1.0, min(width, height)))

        rows.append({
            "file_rgb": row["file_rgb"],
            "file_th": row["file_th"],
            "class_id": row["class_id"],

```

```

        "conf_ens": row["conf_ens"],
        "area_px": row["area_px"],
        "T_avg": T_avg,
        "g_T": g_T,
        "contrast": contrast,
        "edge_density": edge_density,
        "L_ratio": L_ratio
    })

df_feat = pd.DataFrame(rows)
df_feat.to_csv("outputs/features_for_anfis.csv", index=False)
print(f"Saved features: {len(df_feat)} rows")

if __name__ == "__main__":
    process_features()

```

---

### Г.3. Формування навчальної вибірки для ANFIS

У цьому блоці додаємо до ознак експертну оцінку критичності (наприклад, уручну позначену інженерами), щоб мати пари “вхід — вихід” для навчання ANFIS.

```
# file: prepare_anfis_dataset.py
```

```

import pandas as pd

FEATURES_CSV = "outputs/features_for_anfis.csv"
LABELS_CSV = "data/expert_labels.csv" # файл, де зберігається C_exp (експертна
критичність)

def merge_features_labels():
    df_feat = pd.read_csv(FEATURES_CSV)
    df_lbl = pd.read_csv(LABELS_CSV)

    # Припустимо, що в обох файлах є унікальний ключ: file_rgb + class_id +
area_px (або окремий id)
    merged = pd.merge(df_feat, df_lbl, on=["file_rgb", "class_id", "area_px"],
how="inner")

    merged.to_csv("outputs/anfis_training_data.csv", index=False)
    print(f"Merged rows: {len(merged)}")

if __name__ == "__main__":
    merge_features_labels()

```

---

## Г.4. Навчання ANFIS (MATLAB)

Приклад коду для MATLAB, який:

1. зчитує `anfis_training_data.csv`;
2. формує матрицю вхідних ознак;
3. генерує початкову FIS;
4. навчає ANFIS;
5. зберігає навчену систему.

```
% file: train_anfis.m

clc; clear; close all;

% Завантаження даних
data = readtable('outputs/anfis_training_data.csv');

% Формування вхідної матриці X і виходу Y
% Приклад: використовуємо 5 ознак
X = [data.area_px, data.T_avg, data.g_T, data.contrast, data.L_ratio];
Y = data.C_exp; % експертна оцінка критичності (0..1)

trainData = [X, Y];

% Налаштування параметрів ANFIS
numMFs = 3; % кількість MF на вхід
mfType = 'gaussmf'; % тип MF
epoch_n = 120; % кількість епох

% Генерація початкової нечіткої системи
in_fis = genfis1(trainData, numMFs, mfType);

% Навчання ANFIS
[trnFis, trnError, stepSize, chkFis, chkError] = ...
    anfis(trainData, in_fis, ...
        [epoch_n, 0.01, 0.01, 0.9, 1.1], ...
        [], ...
        trainData); % для простоти використовуємо train = check

% Збереження навченої FIS
writeFIS(trnFis, 'models/anfis_wt_defects');
```

```

% Візуалізація навчальної кривої
figure;
plot(1:length(trnError), trnError, 'LineWidth', 2);
grid on;
xlabel('Epoch');
ylabel('Training Error');
title('Наслідок навчання ANFIS');

```

---

## Г.5. Використання навченого ANFIS для оцінювання критичності

```

% file: eval_anfis.m

clc; clear; close all;

% Завантаження навченої моделі
fis = readFIS('models/anfis_wt_defects');

% Приклад вектора ознак (з Python або з CSV)
% [area_px, T_avg, g_T, contrast, L_ratio]
sample = [ 3500, 48.2, 5.7, 21.4, 3.1 ];

C_final = evalfis(fis, sample);

fprintf('Оцінена критичність дефекту: %.3f\n', C_final);

```

---

## Г.6. Місце інтеграції Python + MATLAB

У реальній системі:

1. Python модулі `yolo_ensemble_inference.py` та `feature_extraction_fusion.py`  
→ генерують `features_for_anfis.csv` / `anfis_training_data.csv`.
2. MATLAB-скрипти `train_anfis.m`, `eval_anfis.m`  
→ навчають та застосовують ANFIS.