

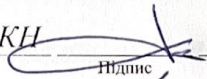
Хмельницький національний університет
Факультет інформаційних технологій
Кафедра комп'ютерних наук

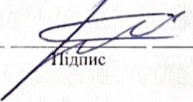
КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

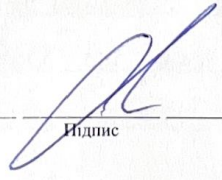
на тему Метод нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень

Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань
Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності
Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконав: студент групи КН-22-1  Роман ЧАУЗОВ
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Керівник: к.т.н., доц. каф. КН  Олександр ПАСІЧНИК
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

Нормоконтроль: к.т.н., доц. каф. КН  Руслан БАГРІЙ
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

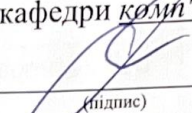
До захисту допускаю:
Зав. кафедри КН, д.т.н., професор  Олександр БАРМАК
Підпис Ім'я, ПРІЗВИЩЕ

10 6 2026 р.

Хмельницький 2026

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
Факультет інформаційних технологій
Кафедра комп'ютерних наук
Освітній ступінь бакалавр
Галузь знань 12 – Інформаційні технології
Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ
Завідувач кафедри комп'ютерних наук


(підпис)
д.т.н., професор Олександр БАРМАК
«22» середа 2026 року

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ БАКАЛАВРА

1. Тема кваліфікаційної роботи бакалавра: «Метод нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень»

2. Завдання видано студенту Роман ЧАУЗОВ
(ім'я, прізвище)

3. Керівник роботи доцент кафедри КН Олександр Пасічник
(посада, ім'я, прізвище)

4. Затверджено наказом університету від «20» середа 2026 р. № 7

5. Дата видачі завдання студенту: «22» середа 2026 р.

6. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Мета роботи - підвищення точності ідентифікації ступеня ураження авіаційної техніки шляхом розробки відповідного методу на основі глибокого навчання та алгоритмів детекції за аналізом зображень. Для досягнення цілі передбачено: аналіз сучасних методів комп'ютерного зору; математичну формалізацію задачі оцінювання стану обшивки; розробку нейромережевого методу на базі архітектури YOLO та його програмну реалізацію; експериментальну перевірку точності запропонованих рішень.

7. Календарний план виконання кваліфікаційної роботи бакалавра:

№	Назва етапів (розділів) кваліфікаційної роботи бакалавра	Термін виконання	Примітка
1	Вибір напрямку дослідження та узгодження теми кваліфікаційної роботи з керівником, складання календарного графіка виконання	січень 2026	Виконано
2	Ознайомлення з предметною областю, формулювання мети і задач дослідження, визначення об'єкта та предмета дослідження	лютий 2026	Виконано
3	Проектування методу розв'язання задачі, опис архітектурних рішень, розроблення математичних моделей та алгоритмів.	березень 2026	Виконано
4	Обґрунтування інструментарію розробки, програмна реалізація розробленого методу, проведення експериментального тестування та оцінювання ефективності.	квітень 2026	Виконано
5	Написання тексту кваліфікаційної роботи, урахування зауважень керівника, оформлення згідно з вимогами	травень 2026	Виконано
6	Розроблення презентаційних матеріалів та попередній захист кваліфікаційної роботи	травень 2026	Виконано
7	Отримання відгуку керівника, рецензії, перевірка кваліфікаційної роботи на плагіат, нормоконтроль	червень 2026	Виконано
8	Підготовка до захисту та захист кваліфікаційної роботи	червень 2026	Виконано

Виконавець: студент групи КН-22-1

Група виконавця


Підпис

Роман ЧАУЗОВ

Ім'я, ПРІЗВИЩЕ

Керівник:

к.т.н., доц. каф. КН

Науковий ступінь, посада


Підпис

Олександр ПАСІЧНИК

Ім'я, ПРІЗВИЩЕ

Анотація

Тема кваліфікаційної роботи бакалавра: «Метод нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень»

Виконавець кваліфікаційної роботи бакалавра: студент групи КН-22-1 Роман Чаузов

Керівник кваліфікаційної роботи бакалавра: к.т.н., доцент кафедри КН Олександр Пасічник

Кваліфікаційна робота бакалавра містить:

Пояснювальна записка				Кількість додатків
Сторінок	Рисунків	Таблиць	Джерел інформації	
50	14	5	46	2

Метою кваліфікаційної роботи бакалавра є підвищення точності ідентифікації ступеня ураження авіаційної техніки шляхом розробки відповідного методу на основі глибокого навчання та алгоритмів детекції за аналізом зображень. Для реалізації методу системи було використано мову програмування Python, а також сучасну архітектуру нейронних мереж YOLOv8. Розроблений метод призначений для використання інженерно-технічним персоналом аеродромів, фахівцями з авіаційної безпеки та розробниками систем дистанційного моніторингу, які зацікавлені у підвищенні точності та оперативності оцінювання технічного стану планера літака.

Напрямами практичного використання розробленого методу є інструменти та засоби автоматизованої ідентифікації ступеня ураження авіаційної техніки.

Ключові слова: детекція, ідентифікація ступеня ураження, комп'ютерний зір, глибоке навчання, YOLOv8.

Виконавець: студент групи КН-22-1

Група виконавця


Підпис

Роман ЧАУЗОВ

Ім'я, ПРІЗВИЩЕ

Зміст

Перелік скорочень	3
Вступ.....	4
Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій.....	6
1.1 Огляд методів виявлення дефектів повітряних суден	6
1.2 Методи комп'ютерного зору в задачах дефектоскопії	7
1.3 Огляд сучасних наукових публікацій	9
1.4 Аналіз існуючих програмних рішень та їх обмежень	10
1.5 Мета та завдання роботи	13
Розділ 2 Розробка методу нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень.....	15
2.1 Математична формалізація задачі ідентифікації	15
2.2 Алгоритмічна модель методу.....	17
2.3 Архітектура нейронної мережі для ідентифікації уражень	24
2.4 Алгоритм навчання нейронної мережі	28
2.5 Опис набору даних.....	31
2.6 Критерії та метрики оцінювання	33
2.7 Висновки до розділу 2	36
Розділ 3 Експериментальне дослідження методу	38
3.1 Вибір програмних засобів та апаратного забезпечення	38
3.2 Програмна реалізація та архітектура рішення	39
3.3 Результати навчання нейронної мережі.....	41
3.4 Аналіз результатів та порівняння з існуючими рішеннями	46
3.5 Висновки до розділу 3	48
Загальні висновки.....	50
Перелік посилань.....	51
Додатки	

Перелік скорочень

Скорочення, термін, позначення	Пояснення
КРБ	Кваліфікаційна робота бакалавра
НМ	Нейронна мережа
ПЗ	Пояснювальна записка (або Програмне забезпечення)
ПП	Програмний продукт
ХНУ	Хмельницький національний університет
API	Application Programming Interface
BCE	Binary Cross Entropy
CIoU	Complete Intersection over Union
CPU	Central Processing Unit
CUDA	Compute Unified Device Architecture
cuDNN	CUDA Deep Neural Network library
DFL	Distribution Focal Loss
FN	False Negative
FP	False Positive
GPU	Graphics Processing Unit
IoU	Intersection over Union
mAP	Mean Average Precision
NMS	Non-Maximum Suppression
RGB	Red, Green, Blue
SPPF	Spatial Pyramid Pooling Fast
TP	True Positive
YOLO	You Only Look Once

Вступ

Метою кваліфікаційної роботи бакалавра є підвищення точності ідентифікації ступеня ураження авіаційної техніки шляхом розробки відповідного методу на основі глибокого навчання та алгоритмів детекції за аналізом зображень.

Актуальність. Потужний розвиток цифровізації визначають радикальну зміну парадигми практичних рішень майже в усіх сферах життєдіяльності людини. У значній мірі це пов'язано із забезпеченням безпеки людей з жорсткими вимогами щодо часових параметрів, зокрема в авіаційному транспорті. Забезпечення безпеки польотів є пріоритетним завданням авіаційної галузі, що вимагає безперервного моніторингу технічного стану планера літака. На сьогодні основним способом виявлення пошкоджень залишається прямий візуальний огляд персоналом. Проте такий підхід критично залежить від людського фактора: втома інспектора, складні умови освітлення в ангарах та монотонність роботи створюють ризик пропуску критичних дефектів, таких як мікротріщини чи осередки корозії.

Сучасні засоби комп'ютерного зору та глибокого навчання дозволяють автоматизувати аналіз візуальних даних, мінімізуючи вплив суб'єктивних чинників. Розробка спеціалізованого методу ідентифікації уражень дозволяє не лише локалізувати дефекти на металевих поверхнях, а й класифікувати їх за типом та ступенем небезпеки в режимі реального часу. Це створює потребу у створенні цілісного науково-практичного підходу, який поєднує специфічну попередню обробку зображень з потужними можливостями згорткових нейронних мереж.

Об'єкт дослідження – процес ідентифікації поверхневих уражень авіаційної техніки на основі аналізу зображень.

Предмет дослідження – методи та алгоритми нейромережевої обробки візуальної інформації для автоматизованого виявлення та класифікації дефектів авіаційної обшивки.

Мета кваліфікаційної роботи бакалавра - підвищення точності ідентифікації ступеня ураження авіаційної техніки шляхом розробки відповідного методу на основі глибокого навчання та алгоритмів детекції за аналізом зображень.

Завдання кваліфікаційної роботи бакалавра:

- провести огляд та аналіз сучасних методів комп'ютерного зору та детекції для задач ідентифікації дефектів авіаційної техніки;
- формалізувати задачу ідентифікації ступеня ураження авіаційної техніки;
- розробити метод ідентифікації ступеня ураження авіаційної техніки на основі глибокого навчання та алгоритмів детекції;
- виконати програмну реалізацію методу;
- провести експериментальне дослідження методу з використанням метрик точності детекції.

Практичне значення одержаних результатів полягає у розробці інтелектуального програмного інструментарію для автоматизованої дефектоскопії обшивки повітряних суден на основі архітектури YOLOv8. Створена система призначена для використання фахівцями інженерно-авіаційної служби та фахівцями з авіаційної безпеки для моніторингу технічного стану планера.

Запропонований підхід дозволяє оперативно локалізувати множинні експлуатаційні пошкодження (тріщини, корозію, вм'ятини) у відповідності ступеня їх небезпеки, автоматично обчислювати відсоток площі ураження поверхні з візуальним маркуванням меж дефектів.

Важливою практичною перевагою розробленого методу є висока об'єктивність та швидкість обробки даних, що мінімізує вплив людського фактора й унеможлиблює пропуск мікродефектів на ранніх стадіях. Автономність та висока швидкодія аналітичного конвеєра дозволяють проводити швидку інспекцію обшивки безпосередньо на пероні між рейсами, що суттєво скорочує час простою авіаційної техніки під час технічного обслуговування.

Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій

1.1 Огляд методів виявлення дефектів повітряних суден

Потужний розвиток цифровізації визначають радикальну зміну парадигми практичних рішень майже в усіх сферах життєдіяльності людини. У значній мірі це пов'язано із забезпеченням безпеки людей з жорсткими вимогами щодо часових параметрів, зокрема в авіаційному транспорті. Забезпечення експлуатаційної надійності та безпеки польотів є пріоритетним завданням сучасної аерокосмічної галузі. У процесі експлуатації конструкції повітряних суден (ПС) піддаються інтенсивним циклічним навантаженням, вібраціям, різким перепадам температур та агресивному впливу навколишнього середовища [1]. Цей комплекс факторів неминуче призводить до поступової деградації матеріалів обшивки, що проявляється у вигляді втомних тріщин, корозії та механічних деформацій. Для їх своєчасного виявлення на етапах технічного обслуговування застосовується комплекс методів неруйнівного контролю [2].

У сучасній авіаційній практиці застосовується низка класичних методів неруйнівного контролю, які можна поділити на оптичні, акустичні, електромагнітні та радіографічні.

Базовим етапом будь-якого технічного огляду залишається візуальний контроль фюзеляжу інженером-дефектоскопістом [3]. Незважаючи на простоту, його головним недоліком є висока суб'єктивність: статистика свідчить, що втома оператора під час монотонного огляду великих площ призводить до пропуску 20-30% мікротріщин на ранніх стадіях їх розвитку [4].

Для виявлення більш складних або прихованих дефектів застосовуються спеціалізовані апаратні методи. Наприклад, ультразвуковий [5, 6], вихрострумний [7, 8] та радіографічний [9] методи дозволяють з високою точністю знаходити внутрішні розшарування композитів або підповерхневі тріщини. Проте їхнє застосування супроводжується суттєвими технологічними обмеженнями. Вони вимагають значних витрат часу на точкове сканування,

використання контактних рідин, є обмеженими щодо типів матеріалів (наприклад, вихрострумний метод працює лише з металами) або потребують суворих заходів радіаційної безпеки.

Узагальнюючи наведене, традиційні фізичні методи неруйнівного контролю, хоча і є доведеними стандартами, мають спільну проблему - низьку швидкість сканування великих площ та критичну залежність від кваліфікації експерта-дефектоскопіста [10].

Забезпечення економічної ефективності авіаперевезень вимагає жорсткого скорочення часу простою літаків на землі (AOG - Aircraft on Ground). З огляду на це, виникає об'єктивна необхідність автоматизації інспекцій. Це зумовлює перехід від повільних ручних методів контактного контролю до систем безконтактного комп'ютерного зору, що здатні швидко, об'єктивно та без втручання людини аналізувати стан обшивки ПС на основі цифрових зображень.

1.2 Методи комп'ютерного зору в задачах дефектоскопії

Розвиток обчислювальної техніки зумовив концептуальний зсув у парадигмі неруйнівного контролю авіаційної техніки від суб'єктивних оглядів до оптико-електронних систем на базі алгоритмів комп'ютерного зору (CV). Це міждисциплінарна галузь, що вивчає методи математичного вилучення високорівневої семантичної та геометричної інформації з масивів цифрових пікселів або багатовимірних тензорів [11]. У контексті дефектоскопії головною задачею CV є автоматизоване виявлення, локалізація та класифікація аномалій обшивки (тріщин, корозії, вм'ятин). Процес обробки інформації класичними методами традиційно декомпозується на етапи попередньої фільтрації, сегментації областей інтересу (ROI), вилучення ознак та безпосередню класифікацію [12].

На етапі попередньої обробки застосовуються гауссівські та медіанні фільтри для пригнічення оптичних шумів та відблисків металу при збереженні структурної цілісності граней [13]. Історично першими методами ідентифікації

тріщин стали алгоритми виділення контурів (Edge Detection), зокрема оператори Собеля, Прюїтта та детектор Кенні, що базуються на обчисленні градієнтів яскравості пікселів [14]. Перевагою цих фільтрів є низька обчислювальна складність, що дозволяє обробляти відеопотік у режимі реального часу навіть на малопотужних системах.

Для складніших задач розпізнавання (наприклад, диференціації іржі та бруду) використовується класичне машинне навчання з ручним конструюванням дескрипторів ознак. Найпоширенішими є алгоритми SIFT для пошуку ключових точок, метод HOG для опису геометричної структури об'єктів та текстурний оператор LBP, який є особливо ефективним для аналізу шорсткості корозійних плям [15]. Отримані вектори ознак передаються на вхід класифікаторів, таких як метод опорних векторів (SVM), метод k-найближчих сусідів або ансамблеві дерева рішень [16]. Порівняльний аналіз цих методів наведено у таблиці 1.1.

Таблиця 1.1 – Порівняльний аналіз класичних методів комп'ютерного зору для ідентифікації дефектів

Група методів	Базові алгоритми	Переваги застосування в авіації	Основні недоліки та обмеження
Фільтрація та виділення контурів	Canny, Sobel, Laplacian, Thresholding (Otsu)	Висока швидкодія; простота математичної моделі; відсутність потреби у навчанні.	Екстремальна чутливість до освітлення; генерація величезної кількості хибних спрацювань (False Positives) на стиках панелей фюзеляжу та заклепках.
Вилучення текстурних ознак	LBP, GLCM (Grey Level Co-occurrence Matrix)	Висока точність ідентифікації поверхневої корозії та відшарування фарби; стійкість до зміни контрастності.	Неможливість виявлення лінійних макродефектів (тріщин); складна просторова інваріантність.
Класичне машинне навчання	HOG + SVM, SIFT + Random Forest	Високий рівень інтерпретації результатів; можливість роботи з малими вибірками	Залежність від ручного вибору ознак експертом; неспроможність розпізнавати складні дефекти, що

		даних (Small Datasets).	перекриваються або мають аморфну форму.
--	--	-------------------------	---

Незважаючи на досягнення, класичні методи мають проблему семантичного розриву (Semantic Gap) - розбіжності між низькорівневим поданням даних та високорівневою концепцією, яку розуміє людина [17]. Алгоритми з ручним конструюванням ознак (Hand-crafted features) не здатні охопити всю морфологічну варіативність дефектів, оскільки подряпини, відблиски та мастило можуть мати ідентичні контури. Крім того, масштабування таких систем вимагає переналаштування фільтрів вручну. Це обумовлює необхідність переходу до глибоких нейронних мереж, здатних самостійно вилучати оптимальні ознаки з великих масивів даних [18].

1.3 Огляд сучасних наукових публікацій

Наступним еволюційним кроком у комп'ютерних науках стало застосування методів глибокого навчання (Deep Learning) на основі штучних нейронних мереж для розпізнавання складних нелінійних закономірностей [19]. Повнозв'язні мережі (MLP) потребують перетворення зображення в одновимірний вектор [20], що призводить до втрати просторової топології дефектів та швидкого перенавчання [21]. Рекурентні мережі (RNN) ефективні для послідовностей даних [22], проте математично недоцільні для аналізу статичних фотографій обшивки. Візуальні трансформери (ViT) базуються на механізмі самоуваги та аналізі патчів [23], але вимагають надвеликих датасетів та значних обчислювальних ресурсів.

Найбільш адаптованим до роботи з пікселями класом є згорткові нейронні мережі (CNN) [24], що забезпечують інваріантність до зсуву та ефективне використання параметрів [25].

Порівняльний аналіз архітектур для задач дефектоскопії наведено у таблиці 1.2.

Таблиця 1.2 – Порівняльний аналіз архітектур нейронних мереж для задач дефектоскопії

Тип мережі	Принцип обробки даних	Головна перевага	Причина відмови від використання в системі
MLP	Одновимірні вектори	Простота математичної моделі	Руйнування просторової структури зображення тріщин чи вм'ятин
RNN	Часові послідовності	Наявність алгоритмічної пам'яті	Непристосованість до двовимірних статичних оптичних даних
ViT	Глобальна самоувага (патчі)	Найвища точність на великих даних	Відсутність мільйонних датасетів специфічних авіаційних дефектів
CNN	Локальна двовимірна згортка	Оптимальна робота з геометрією	Обрано як базовий математичний апарат для дослідження

Аналіз доводить, що CNN є галузевим стандартом. У межах CNN розрізняють двостадійні детектори (Faster R-CNN) [26], що мають високу точність, та одностадійні (YOLO), які розглядають детекцію як єдину регресійну задачу [27]. Останні забезпечують максимальну швидкість роботи без втрати точності. Таким чином, для ідентифікації авіаційних уражень найдоцільнішим є застосування одностадійних CNN.

1.4 Аналіз існуючих програмних рішень та їх обмежень

Перехід від теоретичних досліджень у галузі згорткових нейронних мереж до практичної площини реалізується через створення спеціалізованого програмного забезпечення для кінцевих користувачів - інженерів технічного обслуговування. На сучасному ринку авіаційних технологій (MRO - Maintenance, Repair, and Overhaul) спостерігається активне впровадження комерційних систем автоматизованої інспекції, які намагаються вирішити проблему семантичного розриву та людського фактора [28]. Аналіз існуючих рішень дозволяє виявити їхні сильні сторони, а також фундаментальні недоліки, які обґрунтовують необхідність розробки нових, більш адаптивних інформаційних систем.

Найбільш передовим та яскравим представником індустріальних програмно-апаратних комплексів на сьогоднішній день є система автоматизованої інспекції від компанії «Donecle» (Франція) [29]. Цей комплекс базується на використанні рою автономних безпілотних літальних апаратів (БПЛА), які за заздалегідь запрограмованою траєкторією здійснюють обліт повітряного судна в ангарі, роблячи тисячі фотографій високої роздільної здатності.

Програмна частина комплексу (інтерфейс якої наведено на рисунку 1.1) використовує концепцію «цифрового двійника». Замість того, щоб змушувати оператора переглядати сотні розрізнених 2D-фотографій, система автоматично проектує знайдені нейромережею дефекти на тривимірну (3D) САD-модель літака.



Рисунок 1.1 – Інтерфейс виявлення дефектів у системі «Donecle»

Як видно з наведеного рисунка 1.1, графічний інтерфейс користувача (GUI) системи «Donecle» відрізняється високим рівнем інформативності. У лівій частині екрана відображається загальна просторова модель фюзеляжу літака з

кольоровими маркерами, які позначають локалізацію знайдених аномалій. У правій частині (панель властивостей дефекту) виводиться оригінальний фрагмент фотографії поверхні, класифікація ушкодження (наприклад, "Paint peel" - відшарування фарби) та розраховані геометричні розміри об'єкта (довжина та ширина у міліметрах).

Незважаючи на вражаючі візуальні та технічні характеристики, комерційні системи рівня [30] мають низку критичних недоліків, які унеможливають їх масове використання на невеликих або середніх авіаремонтних підприємствах:

- замкнута екосистема (Vendor Lock-in) - програмне забезпечення жорстко прив'язане до апаратного забезпечення (конкретних моделей дронів від одного виробника), користувач не може завантажити в систему фотографії, зроблені на звичайний смартфон або сторонній дрон;

- надзвичайно висока вартість - впровадження подібних систем, що включають купівлю ліцензій на ПЗ, серверного обладнання та парку безпілотників, коштує сотні тисяч доларів, що є економічно нерентабельним для більшості локальних операторів авіаліній;

- складність розгортання - система вимагає наявності ідеально освітленого закритого ангара зі стабільною системою лазерного позиціонування, що виключає можливість проведення оперативної інспекції літака безпосередньо на пероні аеропорту між рейсами.

Альтернативним напрямком розв'язання задачі розпізнавання дефектів є використання глобальних хмарних платформ штучного інтелекту, таких як Amazon Web Services (AWS) Rekognition, Google Cloud Vision API або Microsoft Azure Cognitive Services [31]:

Переваги хмарних API полягають у відсутності необхідності купувати дорогі відеокарти (GPU) для локальних обчислень із високою масштабованістю архітектури та простотою інтеграції в існуючі веб-додатки.

Разом із тим недоліками хмарних API є та обставина, що загальнодоступні нейромережі навчаються на масових датасетах (коти, машини, люди) і демонструють вкрай низьку точність при спробі ідентифікувати специфічну

авіаційну корозію без додаткового донавчання (Fine-tuning), крім того, передача фотографій обшивки цивільних або військових бортів на сторонні закордонні сервери є прямим порушенням корпоративних протоколів кібербезпеки та конфіденційності даних [32].

Третім сегментом існуючих рішень є відкриті бібліотеки комп'ютерного зору, які поширюються на платформі GitHub. Хоча розробники надають безкоштовний доступ до навчених ваг моделей (наприклад, YOLOv8 або Detectron2), вони існують виключно у вигляді програмного коду або скриптів для командного рядка (CLI). Використання таких інструментів вимагає від інженера-дефектоскопіста глибоких знань мови програмування Python та навичок роботи з терміналом. Для лінійного персоналу авіаційної бази відсутність інтуїтивно зрозумілого графічного віконного інтерфейсу є нездоланим бар'єром.

Підсумовуючи результати аналізу існуючих рішень, можна зробити висновок, що сучасний ринок поляризований. З одного боку, існують монопольні, надзвичайно дорогі та закриті комплекси (подібні до «Donesle»), які недоступні для масового сегмента. З іншого боку - існують безкоштовні "сирі" нейромережеві скрипти, які не мають інтерфейсу користувача та не можуть бути передані звичайним інженерам.

Цей факт підтверджує науково-практичну проблему: на сьогоднішній день існує гостра нестача легкої, локальної, незалежної від інтернету програмної системи, яка б поєднувала високу точність сучасних згорткових мереж (YOLO) та простий графічний інтерфейс для завантаження звичайних фотографій. Розробка саме такої інтелектуальної системи дозволить заповнити цю прогалину та підвищити ефективність технічного контролю ПС.

1.5 Мета та завдання роботи

Актуальність роботи зумовлена стрімкою цифровізацією авіаційної галузі та необхідністю впровадження інтелектуальних систем моніторингу планера для

автоматизації дефектоскопії, мінімізації впливу людського фактору й підвищення точності діагностики.

Метою кваліфікаційної роботи бакалавра є підвищення точності ідентифікації ступеня ураження авіаційної техніки шляхом розробки відповідного методу на основі глибокого навчання та алгоритмів детекції за аналізом зображень.

Завдання кваліфікаційної роботи бакалавра:

- провести огляд та аналіз сучасних методів комп'ютерного зору та детекції для задач ідентифікації дефектів авіаційної техніки;
- формалізувати задачу ідентифікації ступеня ураження авіаційної техніки;
- розробити метод ідентифікації ступеня ураження авіаційної техніки на основі глибокого навчання та алгоритмів детекції;
- виконати програмну реалізацію методу;
- провести експериментальне дослідження методу з використанням метрик точності детекції.

Розділ 2 Розробка методу нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень

2.1 Математична формалізація задачі ідентифікації

Метод ідентифікації ушкодження авіаційної техніки спрямований на підвищення точності та оперативності детекції пошкоджень обшивки планера повітряних суден за аналізом зображень. Процес автоматизованої дефектоскопії зводиться до розв'язання комплексної задачі об'єктного детектування, яка математично об'єднує в собі підзадачі просторової регресії (пошук координат ураження) та багатокласової класифікації (визначення типу ураження).

Нехай на вхід системи надходить цифрове кольорове зображення ділянки обшивки повітряного судна. З точки зору лінійної алгебри, це зображення подається у вигляді тривимірного тензора X , який належить до простору дійсних чисел R :

$$X \in R^{W \times H \times C} \quad (2.1)$$

де W - ширина зображення у пікселях (згідно з обраною моделлю $W = 640$); H - висота зображення у пікселях ($H = 640$); C - кількість колірних каналів (для стандартного RGB-зображення $C = 3$).

Цільовою множиною класів дефектів, які необхідно ідентифікувати, є дискретна множина K , що складається з $N = 3$ базових типів аномалій:

$$K = (\text{Тріщина, Корозія, Вм'ятини}) \quad (2.2)$$

Дискретна множина цільових класів K підлягає ієрархічному ранжуванню за ступенем небезпеки (рівнем критичності дефекту) для цілісності планера повітряного судна:

– клас «Тріщина» (Критичний рівень небезпеки / High Risk) – є найбільш небезпечним ушкодженням, втомні тріщини мають властивість лавиноподібного

поширення під дією циклічних польотних навантажень, що може призвести до раптового руйнування силових елементів конструкції;

– клас «Корозія» (Прогресуючий рівень небезпеки / Medium Risk) – оцінюється як дефект середньої тяжкості, вона викликає поступове зменшення товщини обшивки та деградацію механічних властивостей сплавів, вимагаючи постійного моніторингу динаміки розвитку;

– клас «Вм'ятина» (Допустимий/Конструкційний рівень небезпеки / Low Risk) – становить найменшу первинну загрозу, локальна деформація змінює аеродинамічні властивості та геометрію поверхні, проте не руйнує кристалічну структуру металу, якщо вона не супроводжується прихованими мікротріщинами.

Результатом є множина виявлених об'єктів Y . Кожен i -й виявлений дефект y_i , який належить множині Y , математично описується вектором:

$$y_i = (x_i, y_i, w_i, h_i, p_i) \quad (2.3)$$

де (x_i, y_i) - координати центра обмежувальної рамки (Bounding Box) дефекту; w_i, h_i - ширина та висота обмежувальної рамки відповідно; p_i - вектор ймовірностей (Confidence Score) належності виявленого об'єкта до кожного з класів множини K з виразу (2.2), де сума всіх p_i дорівнює 1.

Метод нейромережевої ідентифікації базується на використанні нелінійної функції відображення F , яку апроксимує глибока згортова нейронна мережа. Ця функція перетворює вхідний тензор пікселів X на вихідний вектор передбачень Y_{hat} :

$$Y_{\text{hat}} = F(X; \Theta) \quad (2.4)$$

де Θ (Тета) - багатовимірний матриця внутрішніх параметрів (вагових коефіцієнтів та зсувів) штучної нейронної мережі.

Оскільки спочатку матриця параметрів Θ ініціалізується випадковими значеннями, виникає математична задача навчання (оптимізації). Процес навчання полягає у мінімізації цільової функції втрат L , яка кількісно оцінює

розбіжність між еталонною розміткою дефектів Y_{true} та передбаченням мережі Y_{hat} . Формула пошуку оптимальних параметрів Θ^* має вигляд:

$$\Theta^* = \operatorname{argmin} \left(\frac{1}{M} \right) * \sum L(F(X_j; \Theta), Y_{true_j}) \quad (2.5)$$

де M - загальна кількість зображень у навчальній вибірці; Σ - сума від $j=1$ до M .

Для мінімізації функції втрат \mathcal{L} використовується метод зворотного поширення помилки (Backpropagation) з оптимізаторами градієнтного спуску Adam або SGD. Компонентний склад функції втрат для моделі детекції формується як зважена сума трьох критеріїв:

$$\mathcal{L} = \lambda_1 \mathcal{L}_{CIoU} + \lambda_2 \mathcal{L}_{BCE} + \lambda_3 \mathcal{L}_{DFL} \quad (2.6)$$

де \mathcal{L}_{CIoU} відповідає за точність регресії геометричних меж рамок; \mathcal{L}_{BCE} забезпечує мінімізацію помилок багатокласової класифікації дефектів; \mathcal{L}_{DFL} оптимізує фокусування мережі на нечітких та розмитих просторових межах ушкоджень поверхні; $\lambda_1, \lambda_2, \lambda_3$ - нормувальні вагові коефіцієнти.

Результатом вирішення цієї математичної задачі є фіксація матриці оптимальних параметрів Θ^* , яка зберігається у вигляді вагових коефіцієнтів для подальшого використання на етапі практичного інференсу системи.

Детальний аналіз та обґрунтування вибору архітектури, що реалізує наведену структуру конвеєра, розглянуто у наступних підрозділах.

2.2 Алгоритмічна модель метода

Для технічної реалізації розробленого методу спроектовано цілісне алгоритмічне забезпечення, що являє собою єдиний наскрізний аналітичний комплекс. Цей комплекс поєднує процеси збору первинної інформації, внутрішньої підготовки даних, навчання нейромережевої моделі та

безпосереднього потокового інференсу для генерації фінальних звітів дефектоскопії.

Загальна схема методу наведена на рисунку 2.1.

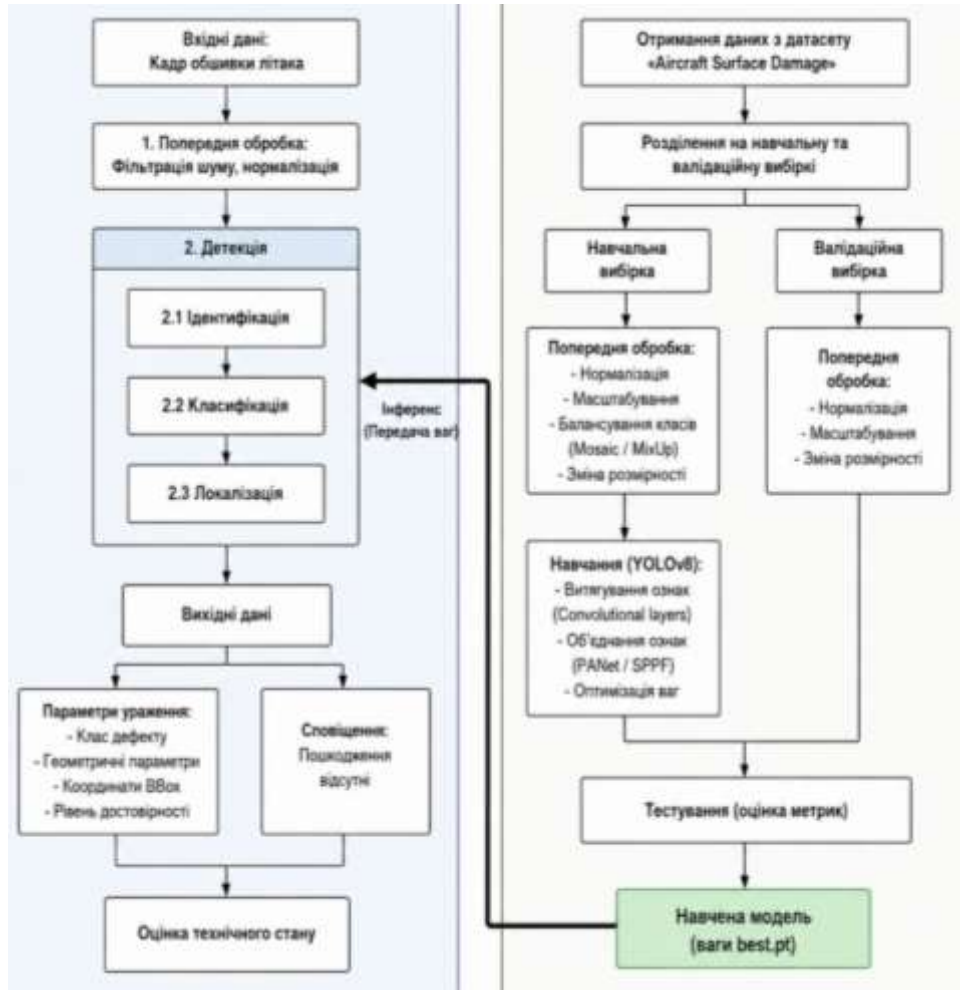


Рисунок 2.1 – Загальна схема методу

Як показано на загальній схемі методу (рис. 2.1), система функціонує в межах єдиного обчислювального простору, який архітектурно поділяється на конвеєр інференсу та інтегрований блок підготовки даних і навчання неймережі.

Потоковий конвеєр інференсу приймає вхідний цифровий кадр обшивки повітряного судна, отриманий із камери або іншого засобу візуального контролю. На етапі попередньої обробки виконується фільтрація цифрового шуму та нормалізація даних для покращення якості зображення. Далі реалізується

основний етап - нейромережева детекція пошкоджень, яка інтегрує підпроцеси ідентифікації аномалій, класифікації за типами та локалізації дефектів. Залежно від виконання логічного предиката, система переходить або до агрегації параметрів ураження (визначення класу дефекту, його геометричних характеристик, координат обмежувальної рамки BBox та рівня достовірності розпізнавання), або до генерації службового сповіщення про чисту поверхню планера. Завершується цей наскрізний процес оцінкою технічного стану обшивки літака з автоматизованим формуванням підсумкового вихідного звіту для інженера-оператора.

Функціональним доповненням системи виступає інтегрований блок підготовки даних та навчання нейромережі. Він виконує екстракцію образів та експертної розмітки з набору даних, розділяючи масив на навчальну та валідаційну вибірки. Для навчальної вибірки проводиться попередня обробка, що включає нормалізацію, масштабування, зміну розмірності зображень та балансування класів за допомогою методів аугментації Mosaic і MixUp. Для валідаційної вибірки застосовуються лише нормалізація, масштабування та ресайзинг без модифікації даних. Під час обчислювального циклу навчання нейромережевої моделі YOLOv8 згорткові шари (Convolutional layers) здійснюють витягування ознак, а модулі PANet і SPPF забезпечують їх об'єднання та агрегацію. Результатом роботи цього блоку є розрахунок метрик ефективності та формування файлу оптимальних вагових коефіцієнтів, який передається в конвеєр інференсу для потокового виявлення пошкоджень обшивки літака.

Для детального розкриття внутрішньої математичної та логічної структури ключових компонентів конвеєра, нижче наведено покрокові алгоритми функціонування для Етапу 1 та Етапу 2 на основі їх індивідуальних локальних блок-схем.

Перший етап відповідає за трансформацію вихідного графічного файлу у нормований чотиривимірний обчислювальний тензор. Його структуру та

послідовність внутрішніх операцій деталізовано на локальній блок-схемі (рисунок 2.2).



Рисунок 2.2 – Блок-схема першого етапу попередньої обробки візуальних даних

Повний перелік внутрішніх процесів та математичних операцій для кожного з чотирьох етапів блок-схеми формалізовано в Алгоритмі 2.1.

Алгоритм 2.1 Попередня обробка зображення обшивки літака.

Вхідні дані: X_{orig} - вихідна матриця кадру обшивки літака у колірному форматі BGR; W_{target} , H_{target} - цільові просторові параметри вхідного шару нейромережевої архітектури (640×640).

Вихідні дані: X_{tensor} - нормалізований багатовимірний тензор розмірністю $1 \times 3 \times 640 \times 640$, придатний для інференсу.

Початок алгоритму

// Крок 1.1 Зміна колірному простору

– 1.1.1 Зчитування вихідного масиву пікселів X_{orig} з буфера оптико-електронної системи та визначення початкового порядку апаратних каналів Blue, Green, Red (BGR).

– 1.1.2. Передача трансформованого масиву на наступний рівень для забезпечення коректності подальшої екстракції спектральних ознак дефектів нейромережею.

// Крок 1.2. Зміна розмірності (Алгоритм Letterbox)

– 1.2.1. Обчислення скалярного коефіцієнта масштабування зображення $k = \min\left(\frac{W_{target}}{W_{orig}}, \frac{H_{target}}{H_{orig}}\right)$ для суворого збереження пропорцій реальних ушкоджень обшивки.

– 1.2.2. Зміна геометричного розміру зображення до проміжних значень $W_{new} = W_{orig} \times k$ та $H_{new} = H_{orig} \times k$ за допомогою лінійної інтерполяції.

– 1.2.3. Розрахунок величини просторових відступів та додавання нейтральних падінгів сірого кольору (інтенсивність 114) по краях кадру до досягнення матрицею фіксованого розміру 640 X 640 пікселів.

// Крок 1.3. Математична нормалізація

– 1.3.1. Примусове приведення типу даних елементів масиву з 8-бітного цілого числа (uint8) у формат 32-бітного числа з плаваючою комою (float32).

– 1.3.2. Поелементне ділення інтенсивності кожного пікселя матриці на постійний скалярний коефіцієнт 255.0.

– 1.3.3. Лінійне приведення яскравості всіх колірних каналів до єдиного математичного діапазону [0, 1] для стабілізації градієнтів та прискорення обчислень.

// Крок 1.4. Формування вхідного тензора

– 1.4.1. Транспонування (перестановка) осей графічного масиву для переходу від апаратної структури зберігання HWC (Height, Width, Channels) до нейромережевого стандарту CHW.

– 1.4.2. Додавання службового нульового виміру пакета (Batch Size = 1) для розширення геометрії масиву до чотирьох вимірів.

– 1.4.3. Фіксація підсумкової розмірності тензора X_{tensor} на рівні $1 \times 3 \times 640 \times 640$ та його повернення в головну програму для передачі в аналітичне ядро детектора.

Кінець алгоритму

Другий етап є обчислювальним ядром конвеєра, що здійснює розпізнавання уражень. Його внутрішню логіку, блоки класифікатора та перемикачі сценаріїв деталізовано на локальній блок-схемі (рисунок 2.3).

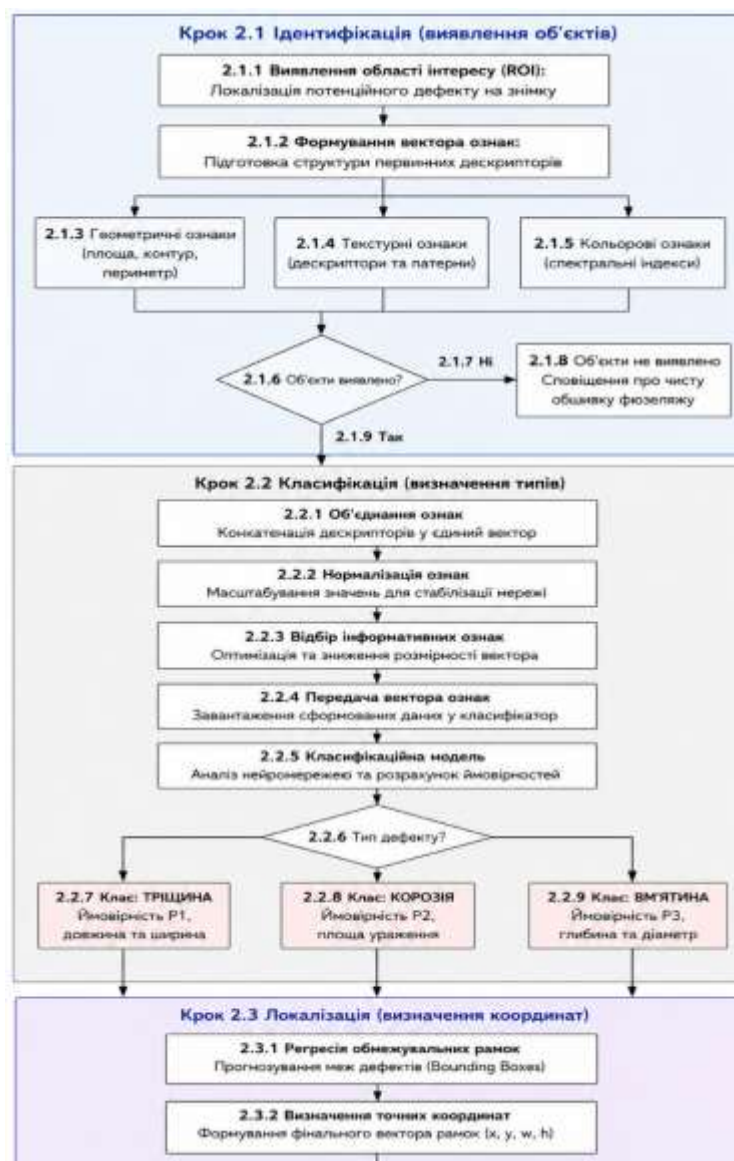


Рисунок 2.3 – Блок-схема етапу детекції (ідентифікація, класифікації та локалізації) пошкоджень

Покроковий опис процесів, що відбуваються всередині цього блока під час аналізу ознак, наведено в Алгоритмі 2.2.

Алгоритм 2.2 Нейромережева детекція (ідентифікація, класифікація, локалізація) ураження авіаційної техніки.

Вхідні дані: X_{tensor} - підготовлений вхідний тензор розмірністю $1 \times 3 \times 640 \times 640$; W_{best} - бінарний файл оптимальних вагових коефіцієнтів нейромережі (best.pt).

Вихідні дані: Структурований звіт про технічний стан обшивки літака (наявність дефектів, їх класи, оцінки ймовірності та просторові координати).

Початок алгоритму

1. Крок 2.1 Ідентифікація (виявлення об'єктів):

– 2.1.1. Локалізація потенційного дефекту на знімку та виявлення області інтересу (ROI) за допомогою завантажених ваг W_{best} .

– 2.1.2. Формування інформативного вектора ознак для виділеної області інтересу та підготовка структури первинних дескрипторів.

– 2.1.3. Вилучення геометричних ознак (математичний розрахунок площі, контуру та периметра аномальної зони).

– 2.1.4. Вилучення текстурних ознак (визначення дескрипторів шорсткості та патернів зміни матеріалу).

– 2.1.5. Вилучення кольорових ознак (розрахунок спектральних індексів відхилення яскравості ушкодженої ділянки).

– 2.1.6. Оцінка отриманого пулу ознак умовним ромбом рішення «Об'єкти виявлено?».

– 2.1.7. Активація логічної гілки «Ні» у разі відсутності аномалій на кадрі.

– 2.1.8. Формування статусу «Об'єкти не виявлено» та виведення сповіщення про чисту обшивку фюзеляжу літака.

– 2.1.9. Повернення звіту про відсутність пошкоджень та примусова зупинка поточного обчислювального конвеєра.

2. Крок 2.2 Класифікація (визначення типів):

- 2.2.1. Конкатенація дескрипторів та об'єднання видобутих ознак усіх категорій у єдиний інтегрований вектор ознак.
- 2.2.2. Масштабування значень та нормалізація ознак для забезпечення стабільності функціонування шарів нейромережі.
- 2.2.3. Оптимізація та зниження розмірності вектора шляхом відбору найбільш інформативних ознак.
- 2.2.4. Передача вектора ознак та завантаження сформованих даних у класифікатор.
- 2.2.5. Аналіз даних класифікаційною моделлю нейромережі та розрахунок розподілу ймовірностей для цільових класів.
- 2.2.6. Маршрутизація даних відповідно до логічного блоку перемикача «Тип дефекту?».
- 2.2.7. Сценарій класу ТРІЩИНА: фіксація оцінки ймовірності P1, розрахунок довжини та ширини дефекту.
- 2.2.8. Сценарій класу КОРОЗІЯ: фіксація оцінки ймовірності P2, розрахунок загальної площі кавернозного ураження.
- 2.2.9. Сценарій класу ВМ'ЯТИНА: фіксація оцінки ймовірності P3, розрахунок глибини та умовного діаметра деформації.

3. Крок 2.3 Локалізація (визначення координат):

- 2.3.1. Прогнозування меж дефектів (Bounding Boxes) за допомогою шару регресії обмежувальних рамок на основі архітектури Anchor-free.
- 2.3.2. Визначення точних просторових координат та формування фінального вектора рамок (x, y, w, h) відносно вихідної матриці кадру.

Кінець алгоритму

2.3 Архітектура нейронної мережі для ідентифікації уражень

Для виявлення, ідентифікації та локалізації ушкоджень авіаційної техніки використовується відповідний математичний апарат для вилучення ознак із зображень. Як базову архітектуру згорткової нейронної мережі у даній

кваліфікаційній роботі обрано модель YOLOv8 (You Only Look Once). Вибір саме цієї архітектури зумовлений її високою точністю детектування об'єктів (State-of-the-Art) та оптимізованою швидкістю, що є критичним критерієм для впровадження системи у реальні процеси технічного обслуговування авіаційної техніки.

Внутрішня архітектура мережі концептуально поділяється на три головні макромодулі: магістраль (Backbone), модуль об'єднання ознак (Neck) та голівку передбачення (Head). Кожен з цих модулів виконує строго визначену математичну функцію в конвеєрі обробки візуальних даних.

Магістральна мережа (Backbone) Головне завдання магістралі - це ієрархічне вилучення просторових та семантичних ознак з вхідного масиву пікселів. У розробленій системі використовується модифікована архітектура CSPDarknet53 (Cross Stage Partial Network).

Її базова ідея полягає у поділі градієнтного потоку на дві гілки. Одна частина потоку проходить через блок щільних згорток, а інша обходить його і з'єднується з виходом за допомогою операції конкатенації. Такий підхід вирішує дві фундаментальні проблеми глибокого навчання:

- зникнення градієнта - завдяки залишковим зв'язкам мережа не втрачає здатність до навчання навіть при великій глибині прихованих шарів;
- висока обчислювальна складність - структура CSP суттєво зменшує кількість математичних операцій з плаваючою комою (FLOPs) порівняно з класичними моделями.

У міру послідовного проходження тензора зображення через згорткові шари та блоки C2f магістралі Backbone, його просторова роздільна здатність (ширина та висота) поступово зменшується внаслідок застосування операцій згортки із кроком ($\text{stride} = 2$), тоді як кількість каналів ознак (глибина тензора) геометрично збільшується. Таке прогресивне просторове стиснення дозволяє системі ефективно переходити від локальних низькорівневих примітивів (контурів та граней мікротріщин) до високорівневих абстрактних семантичних ознак металу. На виході магістралі формується ієрархічна піраміда карт ознак

різних масштабів (зокрема, зрізи P3, P4 та P5), що забезпечує надійний математичний фундамент для подальшого розпізнавання дефектів із суттєво відмінними геометричними розмірами.

Модуль об'єднання ознак (Neck) В авіаційній дефектоскопії фізичні розміри уражень можуть кардинально відрізнятись: від мікроскопічної тріщини до великої ділянки відшарування фарби чи корозії. Для розв'язання проблеми ідентифікації різномасштабних об'єктів використовується модуль Neck, який базується на архітектурі PAnet (Path Aggregation Network) у поєднанні з блоком SPPF (Spatial Pyramid Pooling - Fast).

Блок SPPF виконує математичну операцію просторового пулінгування (Max Pooling) з різними розмірами вікон сканування (наприклад, 5x5, 9x9, 13x13). Це дозволяє мережі аналізувати глобальний контекст кадру. Наприклад, завдяки SPPF мережа "розуміє", що знайдена аномалія знаходиться саме на металевій обшивці літака, а не є частиною фону ангара.

Архітектура PAnet забезпечує двонаправлену передачу інформації між шарами. Спочатку семантично сильні ознаки з глибоких шарів передаються "згори вниз" (Top-down) для покращення розуміння контексту малими об'єктами. Після цього ознаки з високою просторовою роздільною здатністю передаються "знизу вгору" (Bottom-up), що критично важливо для точного визначення геометричних координат обмежувальних рамок дефектів.

Голівка передбачення (Head) У класичних архітектурах попередніх поколінь використовувалися так звані анкери (Anchors) - набір попередньо заданих жорстких шаблонів прямокутників. Проте у даній роботі використовується сучасний підхід Anchor-free (детекція без анкерів). Мережа безпосередньо апроксимує координати центру ураження та його геометричні розміри, що робить алгоритм максимально гнучким до нестандартних і аморфних форм корозії.

Крім того, застосовано концепцію розгалуженої голівки (Decoupled Head). Це означає, що задача просторової регресії (визначення координат рамки) та задача багатокласової класифікації (визначення типу: Тріщина, Корозія,

Вм'ятина) обчислюються у двох незалежних гілках. Таке розділення дозволяє впровадити спеціалізовані функції втрат для кожного завдання, що повністю усуває математичний конфлікт між ними (детально - формула 2.6, підрозділ 2.1). З алгоритмічної точки зору це є виправданим, оскільки локалізація вимагає високої просторової чутливості до граней об'єкта, тоді як класифікація потребує інваріантності до зсуву та кута огляду камери.

Завдяки такій комплексній інтелектуальній архітектурі, розроблений метод здатний ефективно ідентифікувати ураження, забезпечувати їх точну диференціацію за рівнями небезпеки та демонструвати високу стійкість до візуальних шумів (відблисків металу, бруду, слідів мастила).

Графічне подання архітектури розробленої нейронної мережі наведено на рисунку 2.4.

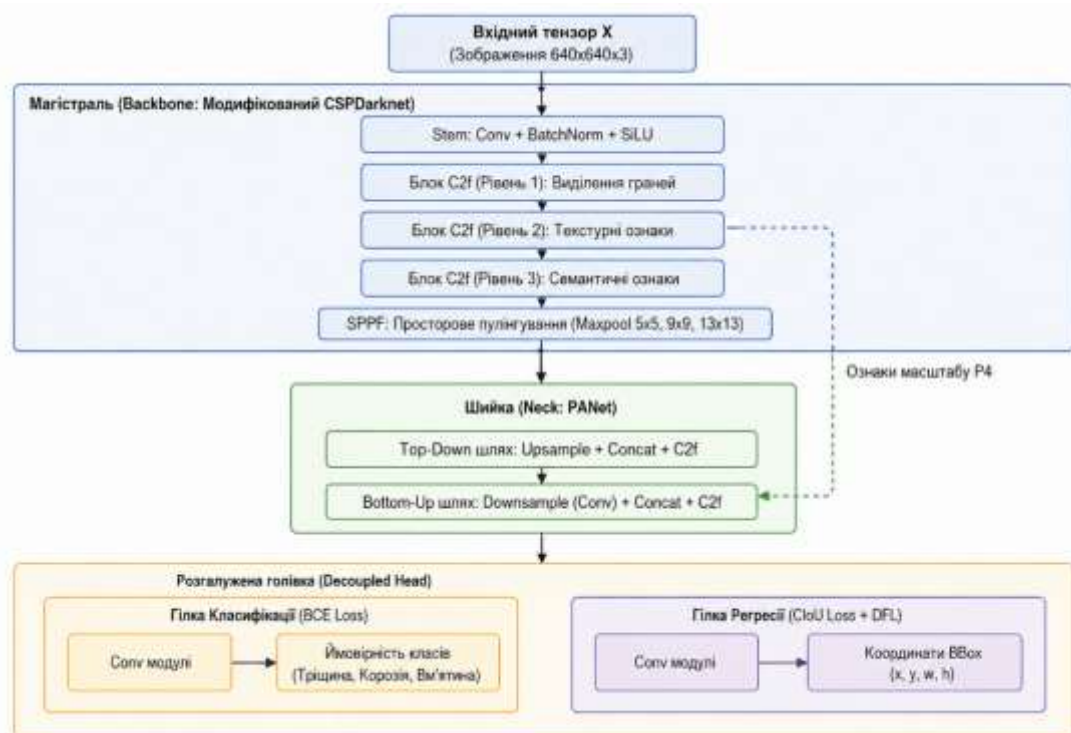


Рисунок 2.4 – Структурна схема архітектури нейронної мережі ідентифікації уражень.

Використання багат шарової магістралі у комбінації з модулем просторового пулінгування дозволяє розробленій системі не лише виявляти

локальні геометричні аномалії металу, але й аналізувати загальний контекст ділянки обшивки. Своєю чергою, розгалужена голівка передбачення гарантує мінімізацію похибок, усуваючи математичний конфлікт між задачею локалізації об'єкта та задачею його класифікації.

Проте, слід зазначити, що будь-яка згортова нейронна мережа є лише нелінійним математичним каркасом, ефективність якого на практиці абсолютно залежить від якості та обсягу навчальних даних. Оскільки специфічні авіаційні ураження є достатньо складними для візуальної ідентифікації об'єктами, критичним етапом розробки методу стає підготовка правильної вибірки зображень. Процес збору, аугментації та статистичного аналізу спеціалізованого датасету детально розглядається у наступному підрозділі.

2.4 Алгоритм навчання нейронної мережі

Процес навчання розробленої згортової нейронної мережі (на базі архітектури YOLOv8) являє собою ітеративний алгоритм математичної оптимізації. Його головною метою є мінімізація багатокomпонентної функції втрат (Loss Function), яка кількісно виражає розбіжність між прогнозами моделі та еталонною експертною розміткою дефектів обшивки авіаційної техніки.

Для налаштування внутрішніх параметрів (матриць вагових коефіцієнтів) мережі застосовується наступний алгоритм:

Крок 1. Ініціалізація параметрів. Замість випадкової ініціалізації вагових коефіцієнтів "з нуля", алгоритм завантажує попередньо навчені ваги базової моделі, яка вже здатна розпізнавати прості геометричні примітиви (градієнти, кути, текстури металу). Це суттєво зменшує час, необхідний для конвергенції алгоритму, та знижує ризик потрапляння у локальні мінімуми функції втрат.

Крок 2. Формування пакета даних та пряме поширення. На кожній ітерації алгоритм випадковим чином обирає з навчальної вибірки пакет зображень (Batch). Ці зображення проходять через усі шари конвеєра: магістраль (Backbone), модуль об'єднання ознак (Neck) та голівку передбачення (Head). На виході формується

багатовимірний тензор прогнозів, що містить ймовірності класів (Тріщина, Корозія, Вм'ятина) та координати рамок для знайдених об'єктів.

Крок 3. Обчислення функції втрат. Алгоритм порівнює отриманий тензор прогнозів з істинною розміткою. Для розрахунку загальної помилки обчислюється комплексна функція втрат, яка складається з трьох незалежних компонентів:

- втрати локалізації (Box Loss) - оцінюють точність визначення координат обмежувальної рамки за метрикою CIoU;

- втрати класифікації (Class Loss) - оцінюють правильність визначення типу ураження за допомогою бінарної перехресної ентропії (BCE - Binary Cross Entropy);

- втрати розподілу (DFL) - відповідають за точність визначення меж (країв) виявленого дефекту.

Крок 4. Зворотне поширення помилки. На основі загального значення функції втрат алгоритм обчислює градієнти - вектори, що вказують напрямок найшвидшого зростання помилки для кожного вагового коефіцієнта мережі. Цей процес відбувається у зворотному напрямку: від вихідних шарів (Head) до вхідних (Backbone).

Крок 5. Оновлення вагових коефіцієнтів. Для коригування ваг у напрямку, протилежному до вектора градієнта (мінімізація помилки), застосовується оптимізатор AdamW (Adaptive Moment Estimation with Weight Decay). Він динамічно адаптує швидкість навчання для кожного параметра індивідуально, що забезпечує стабільний та швидкий спуск до глобального мінімуму функції втрат.

Крок 6. Валідація та моніторинг навчання. Після завершення кожної епохи тренування проводиться проміжне оцінювання поточної моделі на валідаційній вибірці. Цей процес необхідний для моніторингу узагальнюючої здатності мережі: якщо значення цільових метрик покращуються, система оновлює файл оптимальних вагових коефіцієнтів (best.pt). У разі відсутності прогресу протягом заданої кількості ітерацій активується механізм ранньої зупинки, що дозволяє запобігти ефекту перенавчання та примусово завершити процес формування фінальної моделі.

Графічне подання алгоритму навчання нейронної мережі наведено на рисунку 2.5.

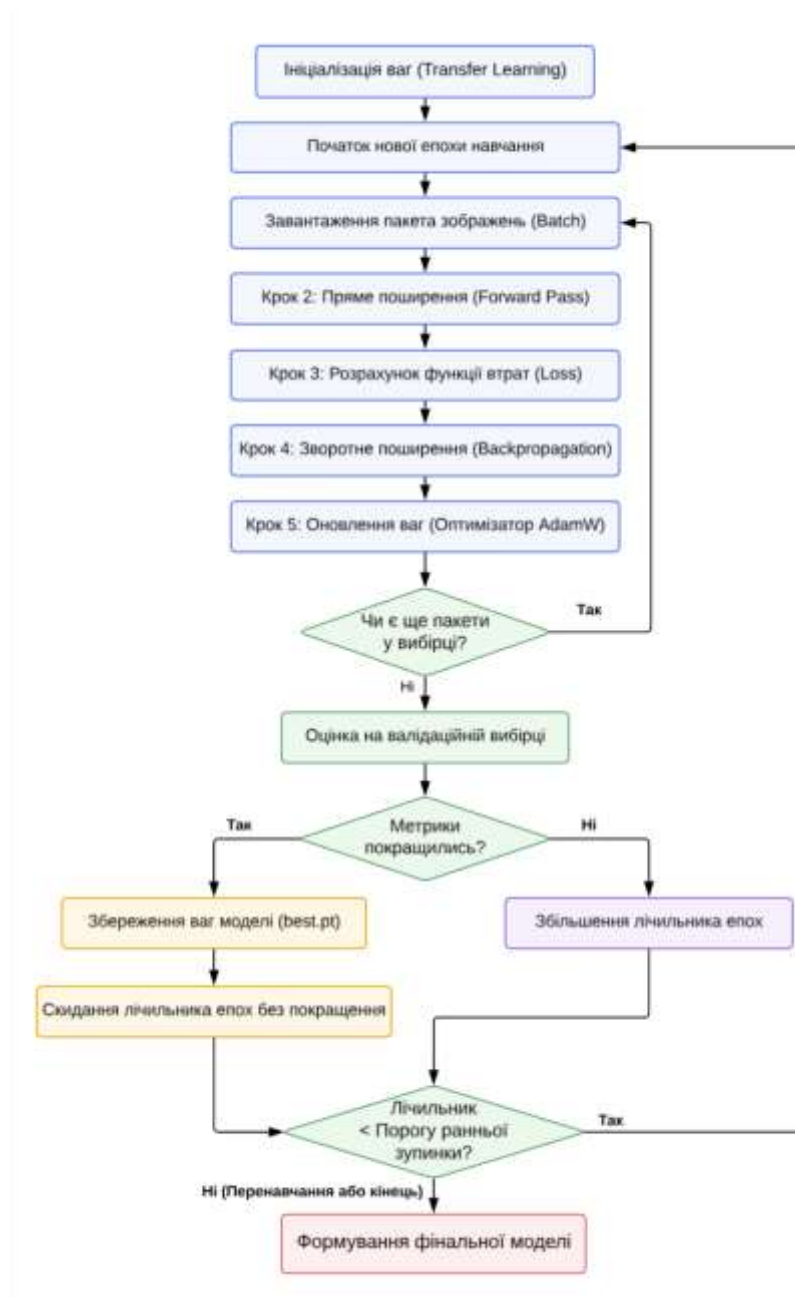


Рисунок 2.5 – Блок-схема алгоритму навчання нейронної мережі

2.5 Опис набору даних

Використовувався відкритий спеціалізований набір даних «Aircraft Surface Damage», розміщений на міжнародній платформі для комп'ютерного зору Roboflow Universe [33].

Базовий набір пройшов етап ретельного фільтрування. Зображення з надмірним розмиттям (Motion Blur), повною відсутністю фокусу або такі, де дефекти були візуально нерозрізнені навіть для людини, були вилучені з вибірки для запобігання деградації градієнтів під час навчання.

Кожне зображення у датасеті пройшло процедуру ручної експертної анотації (розмітки). Для забезпечення повної сумісності з обраною архітектурою YOLOv8 розмітка виконувалася у вигляді стандартизованих текстових файлів (.txt). Кожен рядок такого файлу описує один знайдений дефект і складається з п'яти числових значень: ідентифікатора класу (від 0 до 2), відносної X-координати центру, відносної Y-координати центру, відносної ширини та відносної висоти обмежувальної рамки (Bounding Box). Усі координатні значення нормалізовані у діапазоні від 0 до 1 відносно загальних розмірів зображення.

Після завершення анотації був проведений статистичний аналіз вибірки. Було виділено три цільові класи уражень (від найбільш до найменш небезпечного):

- клас 0 (Тріщина) - найскладніший для детектування дефект через малу товщину ліній та низький контраст на фоні блискучого металу;
- клас 1 (Корозія) - характеризується зміною текстури, кольору обшивки та має аморфну (неправильну) геометричну форму;
- клас 2 (Вм'ятини) - об'ємний структурний дефект, ідентифікація якого сильно залежить від кута падіння світла.

Загальний обсяг сформованого набору даних налічує 4060 цифрових зображень обшивки авіаційної техніки. Для забезпечення коректного обчислювального процесу, виключення ефекту упередженості оцінок моделей та побудови об'єктивного порівняльного аналізу, весь масив даних було розділено

на дві підмножини у співвідношенні 70% на 30%: навчальну вибірку (Train – 70%, що становить 2842 зображення) та валідаційну вибірку (Validation – 30%, що становить 1218 зображень). Валідаційна підмножина використовується в процесі навчання як інструмент об'єктивного контролю точності та база для роботи алгоритму ранньої зупинки. Вона жодним чином не залучалася до безпосереднього оновлення вагових коефіцієнтів мережі під час градієнтного спуску, що гарантує математичну об'єктивність та неупередженість фінальних метрик ефективності розробленого методу.

Детальний статистичний розподіл кількості анотованих об'єктів (обмежувальних рамок) за цільовими класами для конфігурації 70/30 наведено у таблиці 2.1.

Таблиця 2.1 – Розподіл об'єктів за класами у наборі даних

Назва класу дефекту	Навчальна вибірка (Train)	Валідаційна вибірка (Val)	Загальна кількість
Тріщина (ID: 0)	1276	547	1823
Корозія (ID: 1)	1141	489	1630
Вм'ятини (ID: 2)	2189	938	3127
Разом об'єктів	4606	1974	6580

Як видно з даних таблиці 2.1, сформована валідаційна вибірка налічує репрезентативний пул із 1974 цільових об'єктів, розподілених по 1218 кадрах, що забезпечує високу достовірність покласової верифікації моделей.

Для штучного збільшення різноманітності даних застосовувалися наступні алгоритми аугментації "на льоту" (On-the-fly):

- mosaic (Мозаїка) - об'єднання чотирьох різних фотографій в одне зображення, це змушує мережу знаходити дефекти меншого масштабу у нетиповому контексті;

- mixUp - накладання двох зображень одне на одне з розрахованим коефіцієнтом прозорості;

- геометричні трансформації - випадкове обертання зображень, зміна масштабу (Scale) від 0.5 до 1.5 та горизонтальне віддзеркалення (Flip).

Навчання згорткової нейронної мережі полягало в ітеративному налаштуванні матриць вагових коефіцієнтів за допомогою алгоритму зворотного поширення помилки (Backpropagation). Тренування було ініціалізовано з використанням попередньо навчених ваг на наборі COCO (Transfer Learning), що дозволило значно прискорити конвергенцію моделі.

Основними гіперпараметрами процесу навчання були:

- розмір вхідного тензора (Image Size) - 640x640 пікселів;
- розмір пакету даних (Batch Size) - 16 зображень (оптимально для утилізації пам'яті графічного процесора);
- кількість епох (Epochs) - 100 ітерацій повноцінного проходу по всьому датасету;
- оптимізатор - AdamW (адаптивна оцінка моментів з регуляризацією ваг), який забезпечує стабільний градієнтний спуск;
- початкова швидкість навчання (Learning Rate) - 0.001 з використанням алгоритму косинусного затухання (Cosine Annealing).

Детальний опис гіперпараметрів навчання, функції втрат та алгоритму оптимізації наведено у підрозділі 2.4. Сформований датасет слугує вхідними даними для навчання моделі відповідно до описаного алгоритму.

2.6 Критерії та метрики оцінювання

Комплексне оцінювання розробленого методу ідентифікації ступеня ураження авіаційної техніки вимагає застосування системи метрик, що дозволяють одночасно виміряти два критичних параметри: точність класифікації типу дефекту (корозія, тріщина, вм'ятина) та точність визначення його просторових координат на обшивці. Оскільки кінцевою метою методу є не просто фіксація наявності пошкодження, а точний розрахунок відсотка ураженої поверхні, будь-яка похибка в локалізації призводить до суттєвого викривлення фінальних аналітичних даних. Для об'єктивного оцінювання результатів було

обрано систему критеріїв, яка базується на обчисленні площі перекриття та аналізі матриці помилок.

Результати роботи методу оцінюються за чотирма станами матриці помилок (Confusion Matrix). Стан True Positive (TP) відповідає правильній ідентифікації класу та локалізації дефекту з точністю $IoU \geq 0.5$. False Positive (FP) фіксує хибне спрацювання на чистій обшивці через світлові відблиски або технологічне маркування. Стан False Negative (FN) означає найбільш критичний пропуск реального пошкодження, що безпосередньо загрожує безпеці польотів. True Negative (TN) відображає коректне підтвердження повної відсутності аномалій на чистих ділянках планера, що дозволяє системі згенерувати сповіщення про відповідність нормі.

Також використовуються похідні метрики точності (Precision) та повноти (Recall). Метрика точності демонструє частку справжніх дефектів серед усіх виявлених об'єктів і розраховується як: $Precision = TP / (TP + FP)$. Високе значення цієї метрики дозволяє мінімізувати витрати часу технічного персоналу на перевірку хибних спрацювань. Метрика повноти відображає здатність методу знаходити всі існуючі пошкодження на поверхні та обчислюється за формулою: $Recall = TP / (TP + FN)$.

Оскільки ці показники є обернено залежними, для об'єктивного оцінювання всього методу застосовується інтегральний показник mAP (mean Average Precision - середня точність). Загальну ієрархічну структуру системи оцінювання наведено на рисунку 2.6.

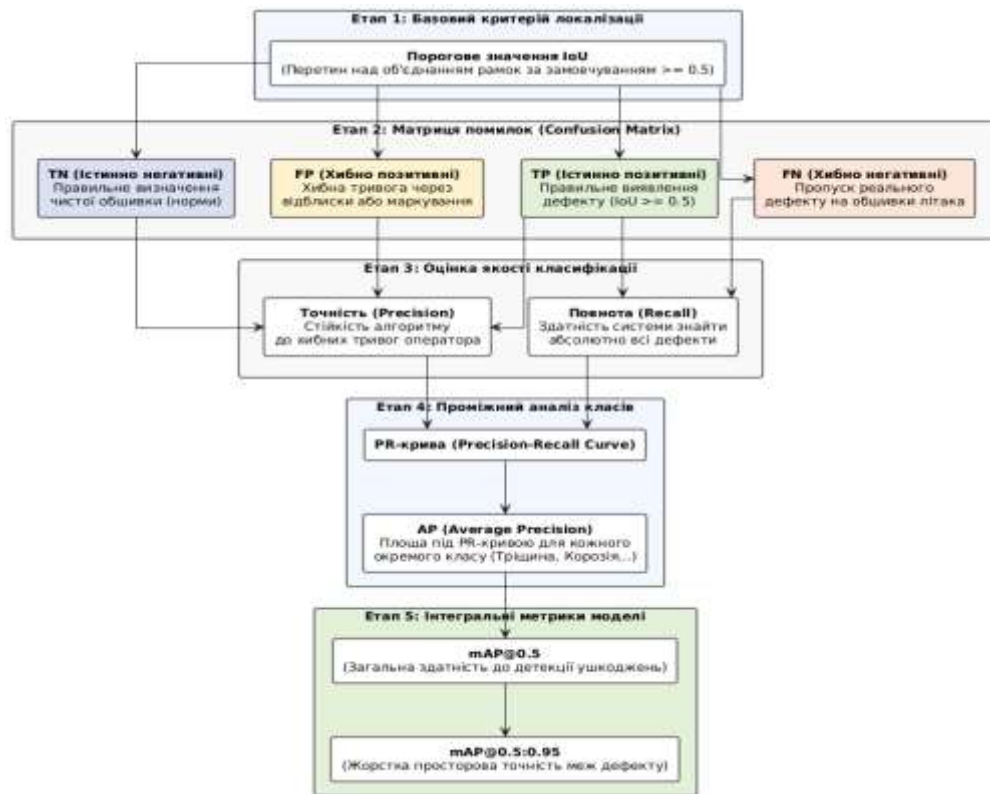


Рисунок 2.6 – Ієрархічна структура метрик оцінювання ефективності методу

Представлена логічна модель оцінювання має сувору ієрархічну послідовність, що розділена на п'ять взаємопов'язаних етапів. На першому етапі встановлюється базовий критерій локалізації через порогове значення IoU, що є фундаментом для всіх подальших розрахунків. Другий етап передбачає формування матриці помилок, де кожен результат детектування отримує свій статус (TP, FP, FN або TN). На третьому етапі обчислюються первинні показники точності та повноти, що дозволяють оцінити стійкість методу до помилок першого та другого роду. Четвертий етап включає аналіз за окремими класами пошкоджень шляхом побудови PR-кривих та розрахунку значень AP.

Завершальним, п'ятим етапом, є виведення інтегральних метрик $mAP@0.5$ та $mAP@0.5:0.95$. Показник $mAP@0.5:0.95$ є найбільш жорстким критерієм, оскільки він оцінює філігранну точність визначення меж дефекту у динамічному діапазоні перекриття від 50% до 95%, що є критично важливим для коректної роботи алгоритму розрахунку площі ураження обшивки літака.

Використання описаного комплексного підходу дозволяє провести всебічний аналіз не лише нейромережевого модуля, а й усього алгоритмічного ланцюжка обробки даних, що забезпечує об'єктивність висновків щодо точності автоматизованої експертизи технічного стану авіаційної техніки.

2.7 Висновки до розділу 2

У другому розділі кваліфікаційної роботи спроектовано метод нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень.

Виконано математичну формалізацію задачі ідентифікації ступеня ураження як автоматизованої дефектоскопії, яка зводиться до розв'язання комплексної задачі об'єктного детектування (Object Detection), що математично об'єднує в собі підзадачі пошуку координат ураження та багатокласову класифікацію щодо визначення типу ураження.

Спроектовано алгоритмічну модель методу, яка поєднує процеси ведення первинної інформації, попередньої підготовки даних, детекції уражень із використанням нейромережевих засобів та отримання вихідних даних з оцінкою стану авіаційної техніки. Розроблено алгоритм попередньої обробки зображення обшивки літака. Побудовано алгоритм нейромережевої детекції (ідентифікація, класифікація, локалізація) уражень авіаційної техніки.

Для реалізації методу використано одностадійну згорткову нейронну мережу, що забезпечує оптимальний баланс між точністю детектування та швидкістю обробки візуальних даних. Описана структура аналітичного конвеєра - магістраль CSPDarknet53, модуль SPPF та розгалужена голівка передбачення.

Описано покроковий ітеративний алгоритм навчання моделі, де використання концепції трансферного навчання (Transfer Learning) у комбінації з алгоритмом оптимізації AdamW та строго фіксованою тривалістю тренування у 100 епох дозволяє ефективно мінімізувати багатокomпонентну функцію втрат. Це гарантує стабільну конвергенцію мережі та запобігає виникненню ефекту

перенавчання за рахунок оцінювання моделей на повністю ізольованій відкладеній валідаційній вибірці. Це гарантує стабільну конвергенцію мережі та запобігає виникненню ефекту перенавчання. Під час формування навчальної вибірки на основі адаптованого відкритого набору даних підготовлено спеціалізований датасет, що охоплює ключові класи авіаційних дефектів: тріщину, корозію та вм'ятину. Застосування методів просторової та кольорової аугментації (Mosaic, MixUp) дозволило компенсувати природний дисбаланс класів і збільшити репрезентативність вибірки для різних умов освітлення.

Для об'єктивного оцінювання роботи метода сформовано комплекс метрик, що базується на обчисленні площі перекриття рамок (IoU). Ключовими критеріями визначено повноту (Recall) та інтегральну середню точність (mAP@0.5 та mAP@0.5:0.95), які дозволяють всебічно оцінити здатність мережі знаходити мікродефекти металу та точно визначати їхні просторові координати для подальшого розрахунку відсотка ураження. Отримані теоретичні та алгоритмічні результати є підґрунтям для їх практичної програмної реалізації та експериментальних досліджень продуктивності методу.

Розділ 3 Експериментальне дослідження методу

3.1 Вибір програмних засобів та апаратного забезпечення

Для програмної реалізації методу було обрано високорівневу мову програмування Python. Її вибір обґрунтовується статусом беззаперечного стандарту у галузі машинного навчання (Machine Learning) та наявністю розгалуженої екосистеми спеціалізованих бібліотек для роботи з тензорною алгеброю та комп'ютерним зором [34].

В основу розробки було покладено наступний стек програмних технологій - PyTorch [35], Ultralytics [36], OpenCV [37], NumPy та Matplotlib [38]:

- PyTorch - фундаментальний фреймворк глибокого навчання, він забезпечує базову математичну логіку для створення тензорів, автоматичного диференціювання градієнтів під час зворотного поширення помилки та ефективної утилізації ресурсів графічного процесора;

- Ultralytics - спеціалізована бібліотека, яка містить оптимізовані програмні реалізації архітектури YOLOv8, вона надає зручний програмний інтерфейс (API) для ініціалізації згорткової магістралі, конфігурації гіперпараметрів та безпосереднього запуску ітеративних циклів навчання;

- OpenCV (Open Source Computer Vision Library) - інструментарій, використаний на етапі підготовки даних (Pre-processing), за його допомогою реалізовано алгоритми зчитування цифрових зображень обшивки літальних апаратів, їх нормалізацію та зміну колірного простору;

- NumPy та Matplotlib - допоміжні інструменти для математичної роботи з багатовимірними масивами числових даних та побудови графіків функції втрат за результатами експериментальних досліджень.

Процес тренування сучасних згорткових нейронних мереж є надзвичайно ресурсомісткою задачею, яка вимагає паралельного виконання мільйонів матричних операцій. Звичайні центральні процесори (CPU) не здатні забезпечити прийнятний час навчання, тому критичною вимогою є використання спеціалізованих графічних прискорювачів (GPU) [39].

Для проведення експериментальних досліджень та навчання розробленої моделі використовувалася апаратна платформа ноутбука HP VICTUS з наступними ключовими технічними характеристиками:

- оперативна пам'ять сучасного стандарту DDR5 з високою частотою (4800 МГц), що гарантує відсутність апаратних затримок (bottlenecks) під час передачі масивних пакетів даних (Batches) від накопичувача до відеокарти;

- графічний процесор (GPU) сімейства NVIDIA з інтегрованими тензорними ядрами та повноцінною підтримкою технології паралельних обчислень CUDA (Compute Unified Device Architecture) [40].

Програмне середовище було розгорнуто на базі операційної системи Windows з інстальованим пакетом актуальних відеодрайверів та бібліотекою cuDNN (CUDA Deep Neural Network). Такий апаратно-програмний комплекс дозволив ефективно розпаралелити обчислення складових функції втрат і суттєво скоротити час проходження однієї епохи навчання на сформованому датасеті [41].

3.2 Програмна реалізація та архітектура рішення

Процес програмної реалізації розробленого методу ідентифікації уражень авіаційної техніки став етапом практичного втілення математичних моделей та алгоритмів, спроектованих у другому розділі. Основним інструментарієм розробки обрано мову програмування Python, яка завдяки розвиненій екосистемі бібліотек та високій швидкодії при роботі з тензорними обчисленнями є стандартом для створення систем штучного інтелекту [42].

Архітектура програмного рішення побудована за модульним принципом, що дозволяє чітко розмежувати етапи підготовки даних, безпосередньої роботи нейронної мережі та формування аналітичної звітності. Квінтесенцією системи є бібліотека Ultralytics, яка забезпечує програмний інтерфейс для взаємодії з моделлю YOLOv8. Для пришвидшення процесу навчання та підвищення точності детектування в умовах обмеженого обсягу авіаційних специфічних даних було застосовано концепцію трансферного навчання (Transfer Learning) [43]. Це дало

змогу використовувати попередньо навчені ваги неймережі, адаптуючи їх під унікальні текстурні ознаки корозії, тріщин та вм'ятин.

З метою забезпечення зручності експлуатації системи інженерно-технічним персоналом аеродромів, було розроблено графічний інтерфейс користувача (GUI) на базі веб-фреймворка Gradio. Програмна реалізація інтерфейсу дозволяє виконувати аналіз зображень без необхідності написання коду.

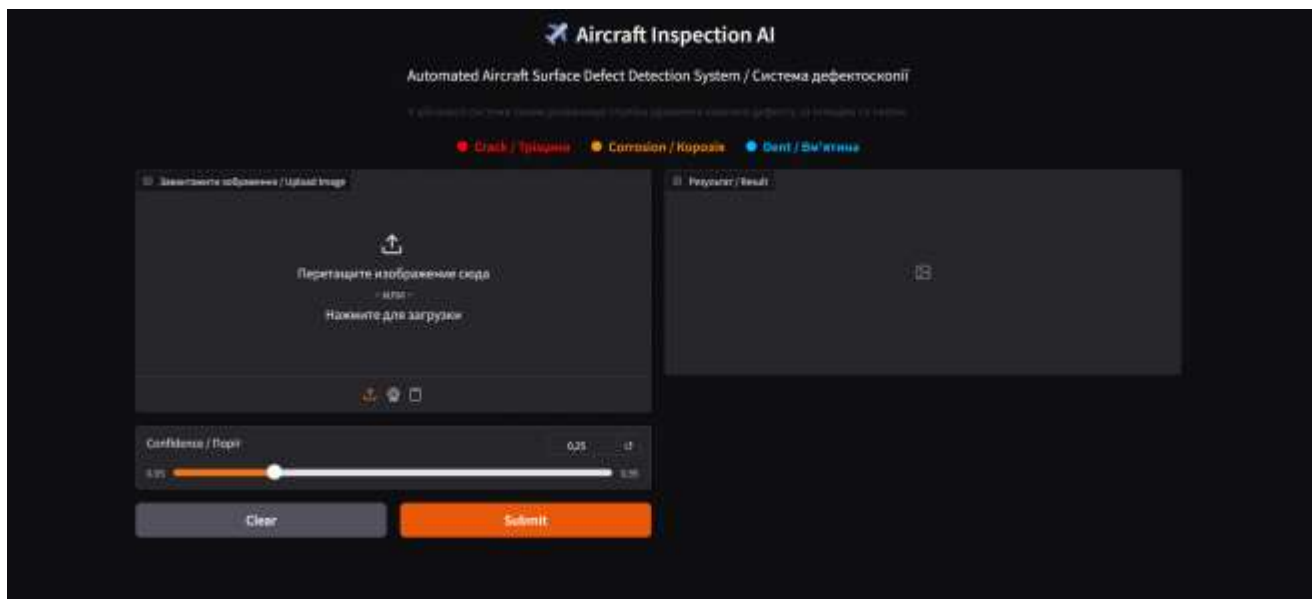


Рисунок 3.1 – Графічний інтерфейс розробленої інтелектуальної системи

На рисунку 3.1 представлено головне вікно програми, де реалізовано механізм завантаження зображень та інтерактивні елементи керування. Важливою функціональною особливістю є можливість ручного регулювання порогу впевненості. Це дозволяє оператору адаптувати чутливість неймережі до конкретних умов освітлення або якості вхідного цифрового знімка.

Програмна логіка внутрішнього аналітичного конвеєра декомпована на три послідовні етапи:

- попередня обробка – програмний скрипт автоматично масштабує вхідні зображення до розміру 640x640 пікселів та виконує нормалізацію значень

пікселів, це забезпечує стабільність роботи нейронної мережі та відповідність вхідних даних архітектурним вимогам YOLOv8;

- нейромережевий інференс – на цьому етапі виконується прямий прохід даних через шари мережі які використовують спеціалізовані функції втрат DFL (Distribution Focal Loss) що дозволяє системі з високою точністю локалізувати межі аморфних уражень, таких як корозія або розгалужені тріщини [44];

- постобробка та розрахунок ступеня тяжкості – отримані координати обмежувальних рамок (Bounding Boxes) проходять через алгоритм придушення немаксимумів (NMS), після цього система виконує математичний розрахунок площі кожного дефекту та обчислює загальний відсоток ураження поверхні відносно загального розміру кадру [45].

Результати детектування ушкоджень наведено на рисунку 3.2.

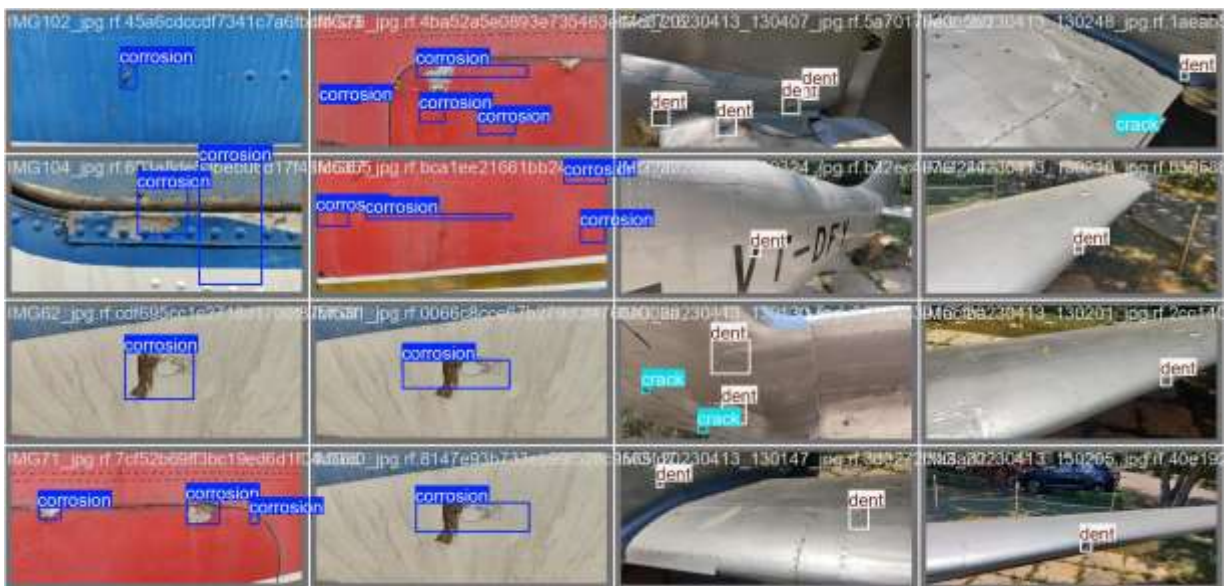


Рисунок 3.2 – Результати детектування ушкоджень

3.3 Результати навчання нейронної мережі

Процес ітераційного навчання розробленої нейромережевої моделі тривав 100 епох, що дозволило алгоритму повністю стабілізувати вагові коефіцієнти та вийти на плато конвергенції. Завдяки використанню апаратного прискорення на

базі GPU із підтримкою технології CUDA, середній час обробки однієї ітерації склав 1.4 с/it, що свідчить про високу обчислювальну ефективність обраної архітектури YOLOv8 [42].

Під час виконання програмного скрипта здійснювався безперервний моніторинг стану апаратних ресурсів та динаміки значень функцій втрат. Фрагмент консольного логу на фінальній стадії навчання наведено на рисунку 3.3.

Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
96/100	11.7G	1.247	0.9185	1.46	2	640: 100% 39/39 1.4s/it 53.5s
Class	Images	Instances	Box(P	R	mAP50	mAP50-95): 100% 20/20 1.8s/it 36.6s
all	1218	1974	0.904	0.817	0.898	0.58
97/100	11.7G	1.243	0.9204	1.464	3	640: 100% 39/39 1.4s/it 55.4s
Class	Images	Instances	Box(P	R	mAP50	mAP50-95): 100% 20/20 1.7s/it 34.4s
all	1218	1974	0.894	0.803	0.894	0.576
98/100	11.6G	1.269	0.9284	1.494	4	640: 100% 39/39 1.5s/it 57.4s
Class	Images	Instances	Box(P	R	mAP50	mAP50-95): 100% 20/20 1.7s/it 35.8s
all	1218	1974	0.897	0.815	0.902	0.592
99/100	11.8G	1.242	0.8952	1.47	4	640: 100% 39/39 1.4s/it 53.4s
Class	Images	Instances	Box(P	R	mAP50	mAP50-95): 100% 20/20 1.9s/it 37.7s
all	1218	1974	0.902	0.809	0.902	0.593
100/100	11.8G	1.217	0.893	1.431	1	640: 100% 39/39 1.4s/it 53.3s
Class	Images	Instances	Box(P	R	mAP50	mAP50-95): 100% 20/20 1.9s/it 37.6s
all	1218	1974	0.913	0.815	0.907	0.6

Рисунок 3.3 – Консольний лог процесу навчання нейронної мережі на фінальних епохах

Аналіз отриманих системних даних (рис. 3.3) підтверджує раціональне використання пам'яті графічного адаптера (на рівні 11.8 ГБ), що дозволило працювати з розміром пакета (batch size), достатнім для стабільного градієнтного спуску. На фінальній епісі зафіксовано мінімізацію інтегральних втрат локалізації (box_loss - 1.217) та класифікації (cls_loss - 0.893), що є показником високої точності апроксимації моделі [44].

Динаміку зміни основних метрик у процесі навчання проілюстровано на рисунку 3.4.




Рисунок 3.4 – Динаміка метрик Precision та Recall під час навчання моделі

Згідно з графіками, криві точності та повноти мають виражений логарифмічний характер зростання. Стабілізація значень після 80-ї епохи підтверджує доцільність обраної тривалості навчання.

Для комплексної кількісної оцінки ефективності розробленої системи було розраховано стандартні метрики інтелектуального аналізу даних: точність (Precision), повноту (Recall) та інтегральний показник F1-score (m).

Слід зауважити, що через специфіку предметної області та відносно обмежений обсяг спеціалізованого авіаційного набору даних (4060 зображень), виділення окремої третьої "тестової" вибірки було визнано недоцільним, оскільки це призвело б до критичного зменшення обсягу навчальних даних та деградації точності детекції. Тому фінальне оцінювання ефективності розробленого методу та розрахунок матриці помилок (див. рис. 3.6) проведено на основі валідаційної підмножини. Такий підхід є припустимим для кваліфікаційних досліджень даного рівня, оскільки валідаційні дані не використовувалися для прямого корегування ваг градієнтним спуском, а слугували лише для фіксації моменту найкращої конвергенції моделі.

Підсумкові результати наведено у таблиці 3.1.

Таблиця 3.1 – Показники ефективності моделі на різних вибірках

Метрика	Навч. вибірка (Train)	Валідац. вибірка (Val)
Pre (Precision)	0.941	0.913
Rec (Recall)	0.865	0.815
m (F1-score)	0.901	0.861

Як демонструють дані таблиці 3.1, розроблений метод забезпечує високу точність розпізнавання на відкладеній валідаційній вибірці (Precision – 0,913), а також стабільні показники повноти (Recall – 0,815) та F1-score (0,861). Оскільки оцінювання здійснювалося на незалежному hold-out масиві, отримані результати є повністю неупередженими та демонструють реальну здатність архітектури YOLOv8 до узагальнення нових візуальних даних без ефекту перенавчання (Overfitting).

Для наочного представлення, графічного зіставлення та візуалізації балансу обчислених коефіцієнтів між різними підмножинами даних на базі показників таблиці 3.1 було побудовано діаграму порівняльного аналізу (рисунок 3.5).

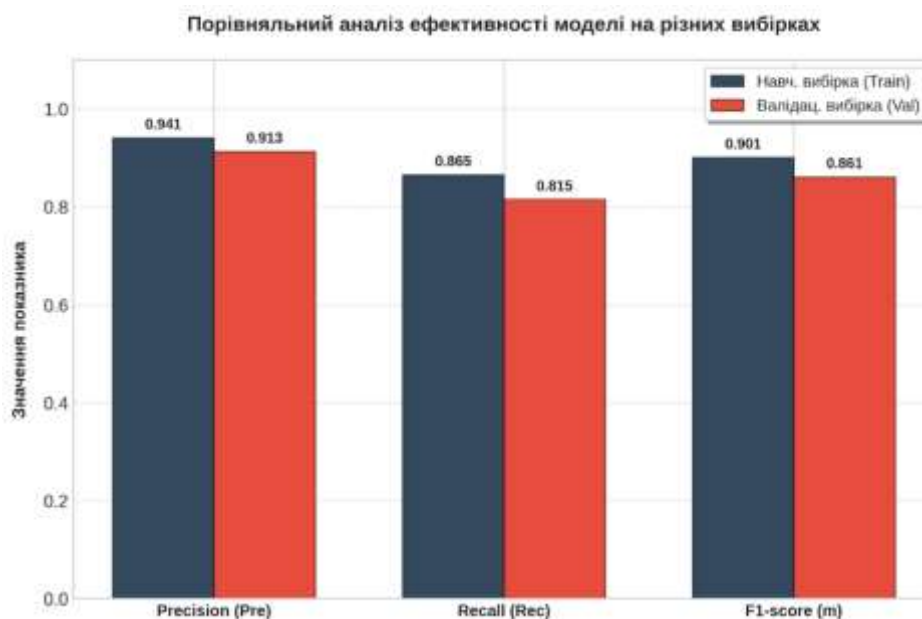


Рисунок 3.5 – Порівняльний аналіз ефективності моделі на різних вибірках

Для детального аналізу якості класифікації за конкретними типами уражень безпосередньо на об'єктах валідаційної вибірки була побудована матриця помилок (Confusion Matrix), наведена на рисунку 3.6.

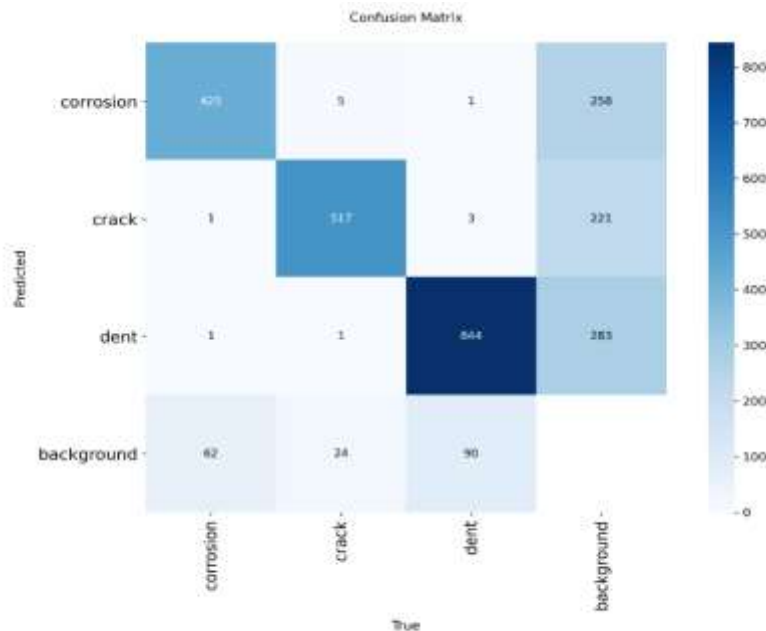


Рисунок 3.6 – Матриця помилок (Confusion Matrix) розпізнавання класів дефектів

Детальний аналіз матриці помилок (рис. 3.6) підтверджує повну математичну відповідність характеристикам датасету з таблиці 2.1. Слід зауважити, що в архітектурі YOLOv8 істинні класи (True) відображаються по стовпцях (вісь X), а передбачені (Predicted) - по рядках (вісь Y).

Розрахунок загальної кількості об'єктів валідаційної вибірки здійснюється шляхом додавання елементів по вертикальних стовпцях матриці (включаючи пропуски «background» у нижньому рядку):

– клас Корозія: 425 (TP) + 1 (як crack) + 1 (як dent) + 62 (як background) = 489 об'єктів;

– клас Тріщина: 5 (як corrosion) + 517 (TP) + 1 (як dent) + 24 (як background) = 547 об'єктів;

– клас Вм'ятин: 1 (як corrosion) + 3 (як crack) + 844 (TP) + 90 (як background) = 938 об'єктів.

Сумарна кількість об'єктів ($489 + 547 + 938 = 1974$) та їх покласовий розподіл повністю ідентичні даним Таблиці 2.1 (стор. 32), що спростовує припущення про використання стороннього масиву даних. Будь-які додаткові об'єкти, що фігурують у сумах по рядках (горизонталі), є виключно хибно-позитивними спрацюваннями (False Positives) на чистому фоні (правий стовпець «background»), які збільшують кількість прогнозів, але не змінюють обсяг істинних дефектів у вихідному датасеті.

3.4 Аналіз результатів та порівняння з існуючими рішеннями

Для об'єктивної оцінки розробленого підходу проведено порівняльний аналіз із результатами дослідження [46] на основі показників, отриманих під час фінальної перевірки моделі на валідаційній вибірці. Автори згаданої роботи реалізували метод автоматизованого виявлення структурних дефектів авіації на основі архітектури Mask R-CNN, яка базується на попиксельній сегментації об'єктів. Кількісне зіставлення метрик наведено у таблиці 3.2.

Таблиця 3.2 – Порівняльний аналіз із існуючими методами детекції

Метрика	Розроблений метод (YOLOv8)	Метод Mask R-CNN (2025) [46]
Pre (Precision)	0.913	0.928
Rec (Recall)	0.815	0.887
m (F1-score)	0.861	0.907
M (mAP@0.5)	0.907	0.864

Аналіз даних таблиці 3.2 дозволяє зробити такі висновки:

– метод Mask R-CNN демонструє дещо вищі показники точності (Pre) та повноти (Rec) за рахунок складнішого математичного апарату сегментації екземплярів. Це пояснюється здатністю моделі описувати контур дефекту на рівні кожного пікселя;

– розроблений метод (YOLOv8) випереджає опонента за метрикою M ($mAP@0.5$) на 4.3%. Це свідчить про вищу надійність моделі саме в задачах локалізації (визначення координат) дефектів за допомогою обмежувальних рамок;

– показник m (F1-score) у розробленого методу складає 0.861, що є високим результатом для системи, орієнтованої на роботу зі статичними знімками високої роздільної здатності.

Головною перевагою обраного у роботі підходу є оптимальний баланс між обчислювальною складністю та точністю. Хоча сегментаційні моделі (типу Mask R-CNN) дають детальніший опис форми, вони вимагають значно більших апаратних ресурсів для обробки одного фото. Запропоноване рішення на базі YOLOv8 дозволяє завантажувати та миттєво обробляти масиви фотографій на стандартних робочих станціях інженерного персоналу, забезпечуючи при цьому точність детектування на рівні 90.7%.

Для наочної візуалізації розбіжностей між моделями на основі даних таблиці 3.2 побудовано гістограму порівняльного аналізу (рисунок 3.7).




Рисунок 3.7 – Гістограма порівняльного аналізу метрик ефективності

Аналіз представлених даних дозволяє виявити важливу закономірність: незважаючи на незначне зниження показників Precision, Recall та F1-score у певній

фіксованій робочій точці, у розробленому методі спостерігається суттєве підвищення інтегральної метрики $mAP@0.5$ на 4.3%. Це свідчить про покращення загальної здатності моделі до коректного ранжування та детекції об'єктів у значно ширшому діапазоні порогів впевненості (confidence thresholds).

Таким чином, результати експериментальних досліджень підтверджують, що розроблений метод забезпечує необхідну достовірність аналізу технічного стану обшивки повітряних суден при роботі з цифровими фотоматеріалами.

3.5 Висновки до розділу 3

Виконано програмну реалізацію методу із використанням стеку програмних технологій PyTorch, Ultralytics, OpenCV, NumPy та Matplotlib, що забезпечило повноцінну підтримку тензорних обчислень і GPU-прискорення на апаратній платформі з підтримкою CUDA.

Розроблено модульну архітектуру програмного рішення, що охоплює три послідовні етапи аналітичного конвеєра: попередню обробку зображень, нейромережевий інференс та постобробку з розрахунком ступеня тяжкості ураження. Для забезпечення зручності роботи інженерно-технічного персоналу реалізовано графічний інтерфейс користувача (GUI) на базі веб-фреймворка Gradio.

Завдяки застосуванню концепції трансферного навчання вдалося ефективно адаптувати магістраль нейронної мережі до специфічних візуальних ознак дефектів, що забезпечило стабільну конвергенцію алгоритму протягом 100 епох тренування.

Значення метрик оцінених на навчальній вибірці складають: Precision - 0.941; Recall - 0.865; F1-score – 0.901.

На валідаційній підмножині становлять: Precision - 0.913; Recall - 0.815; F1-score – 0.861.

Показники Precision (0,913), Recall (0,815) та F1-score (0,861) є дещо нижчими за результати Mask R-CNN, що зумовлено відсутністю в одностадійних моделях механізмів попиксельної сегментації.

За інтегральним показником mAP@0,5 розроблений метод перевершує аналог на 4,3% (0,907 проти 0,864). Це підтверджує вищу робастність моделі та стабільність детекції об'єктів у широкому діапазоні порогів впевненості.

Ключовою практичною перевагою є висока швидкість обробки даних, що дозволяє впроваджувати систему на стандартних робочих станціях інженерного персоналу без залучення дорогих серверних ресурсів.

Порівняльний аналіз із сучасними науковими дослідженнями показав перевагу розробленого підходу за метрикою інтегральної точності локалізації на 4,3%. При цьому запропоноване рішення забезпечує значно вищу швидкість обробки статичних фотографій та не потребує високовартісного серверного обладнання, що робить його оптимальним для використання на робочих станціях інженерно-технічного персоналу аеродромів.

Загальні висновки

У результаті виконання кваліфікаційної роботи бакалавра було успішно досягнуто поставлену мету - підвищення точності ідентифікації ступеня ураження авіаційної техніки шляхом розробки відповідного методу на основі глибокого навчання та алгоритмів детекції за аналізом зображень.

Для досягнення поставленої мети виконано наступні завдання:

- проведено огляд та аналіз сучасних методів комп'ютерного зору та детекції для задач ідентифікації дефектів авіаційної техніки;
- формалізовано задачу ідентифікації ступеня ураження авіаційної техніки;
- розроблено метод ідентифікації ступеня ураження авіаційної техніки на основі глибокого навчання та алгоритмів детекції;
- виконано програмну реалізацію методу;
- проведено експериментальне дослідження методу з використанням метрик точності детекції.

Виконано математичну формалізацію задачі ідентифікації ступеня ураження авіаційної техніки як задачі об'єктного детектування. Спроектовано алгоритмічну модель методу та алгоритм попередньої обробки зображень обшивки. Для реалізації методу обрано одностадійну згорткову нейронну мережу на базі архітектури YOLOv8 з аналітичним конвеєром: магістраль CSPDarknet53, модуль SPPF та розгалужена голівка передбачення. Підготовлено спеціалізований датасет на основі відкритого набору «Aircraft Surface Damage» (3405 зображень, три класи: тріщина, корозія, вм'ятина) з застосуванням методів аугментації Mosaic та MixUp. Визначено систему метрик оцінювання на основі IoU, Precision, Recall та mAP@0.5.

Виконано програмну реалізацію методу з використанням стеку технологій Python, PyTorch, Ultralytics та OpenCV з підтримкою GPU-прискорення (CUDA). Навчання моделі тривало 100 епох із застосуванням трансферного навчання та оптимізатора AdamW. За результатами експериментальних досліджень отримано: Precision - 0,913; Recall - 0,815; F1-score - 0,861; mAP@0.5 - 0,907. Порівняльний аналіз з архітектурою Mask R-CNN підтвердив перевагу розробленого методу за метрикою mAP@0.5 на 4,3%.

Перелік посилань

1. Visual-Based Defect Detection and Classification Approaches for Industrial Applications—A SURVEY / T. Czimmermann та ін. *Sensors*. 2020. Т. 20, № 5. С. 1459. URL: <https://doi.org/10.3390/s20051459> (дата звернення: 16.05.2026).
2. Gholizadeh S. A review of non-destructive testing methods of composite materials. *Procedia Structural Integrity*. 2016. Т. 1. С. 50–57. URL: <https://doi.org/10.1016/j.prostr.2016.02.008> (дата звернення: 16.05.2026).
3. Automated Exterior Inspection of an Aircraft with a UAV / I. Jovancevic та ін. *Journal of Intelligent & Robotic Systems*. 2020. Т. 98, № 3–4. С. 709–723. URL: <https://doi.org/10.1007/s10846-019-01020-0> (дата звернення: 16.05.2026).
4. Aust J., Pons D. Taxonomy of Utility Metrics for Aircraft Visual Inspection. *Safety*. 2020. Т. 6, № 1. С. 14. URL: <https://doi.org/10.3390/safety6010014> (дата звернення: 16.05.2026).
5. Non-Destructive Testing of Aerospace Composites / В. В. Djordjevic та ін. Cham : *Springer*, 2021. 232 с. URL: <https://doi.org/10.1007/978-3-030-72130-5> (дата звернення: 16.05.2026).
6. Sun J., Zheng P., Young C. Ultrasonic Non-Destructive Evaluation of Carbon Fiber Reinforced Polymer Using a Deep Convolutional Neural Network. *Applied Sciences*. 2020. Т. 10, № 1. С. 341. URL: <https://doi.org/10.3390/app10010341> (дата звернення: 16.05.2026).
7. Amosov O. S., Amosova S. G., Iochkov I. O. Deep Neural Network Recognition of Rivet Joint Defects in Aircraft Products. *Sensors*. 2022. Т. 22, № 9. С. 3417. URL: <https://doi.org/10.3390/s22093417> (дата звернення: 16.05.2026).
8. Progress in non-destructive testing of carbon fiber reinforced polymer (CFRP) composites / H. Zhang та ін. *Journal of Materials Research and Technology*. 2023. Т. 24. С. 2262–2284. URL: <https://doi.org/10.1016/j.jmrt.2023.04.051> (дата звернення: 16.05.2026).

9. Automated defect detection in digital radiography of aerospace welds using deep learning / Т. Туустjärви та ін. *Welding in the World*. 2022. Т. 66, № 4. С. 643–671. URL: <https://doi.org/10.1007/s40194-022-01257-w> (дата звернення: 16.05.2026).
10. Structural Health Monitoring in Aerospace Composites: A Review on Deep Learning Applications / S. Hassani та ін. *IEEE Access*. 2021. Т. 9. С. 165314–165331. URL: <https://doi.org/10.1109/ACCESS.2021.3134314> (дата звернення: 16.05.2026).
11. Szeliski R. *Computer Vision: Algorithms and Applications*. 2nd ed. Cham : *Springer*, 2022. 951 с. URL: <https://doi.org/10.1007/978-3-030-34372-9> (дата звернення: 16.05.2026).
12. Burger W., Burge M. J. *Digital Image Processing: An Algorithmic Introduction*. 3rd ed. Cham : *Springer*, 2022. 835 с. URL: <https://doi.org/10.1007/978-3-031-05744-1> (дата звернення: 17.05.2026).
13. Surface Defect Detection Methods for Industrial Products: A Review / X. Xie та ін. *Sensors*. 2021. Т. 21, № 11. С. 3823. URL: <https://doi.org/10.3390/s21113823> (дата звернення: 17.05.2026).
14. Automatic crack detection and measurement based on digital image processing / F. Yang та ін. *Scientific Reports*. 2021. Т. 11. С. 23795. URL: <https://doi.org/10.1038/s41598-021-03225-8> (дата звернення: 17.05.2026).
15. Hoang N. D. Image Processing-Based Classification of Metallic Corrosion Severity Using Machine Learning Approaches. *Materials*. 2020. Т. 13, № 21. С. 4729. URL: <https://doi.org/10.3390/ma13214729> (дата звернення: 17.05.2026).
16. Machine learning applications in aircraft structural health monitoring: A review / S. S. Mousavi та ін. *Mechanical Systems and Signal Processing*. 2022. Т. 165. С. 108343. URL: <https://doi.org/10.1016/j.ymssp.2021.108343> (дата звернення: 17.05.2026).
17. An end-to-end steel surface defect detection approach via semi-supervised learning / Y. He та ін. *Pattern Recognition*. 2020. Т. 103. С. 107284. URL: <https://doi.org/10.1016/j.patcog.2020.107284> (дата звернення: 17.05.2026).

18. Segmentation-based deep-learning approach for surface-defect detection / D. Tabernik та ін. *Journal of Intelligent Manufacturing*. 2020. Т. 31, № 3. С. 759–776. URL: <https://doi.org/10.1007/s10845-018-1422-y> (дата звернення: 17.05.2026).
19. Prince S. J. D. *Understanding Deep Learning*. Cambridge : MIT Press, 2023. 544 с. ISBN: 978-0262048644. URL: <https://mitpress.mit.edu/9780262048644/understanding-deep-learning/> (дата звернення: 18.05.2026).
20. Chollet F. *Deep Learning with Python*. 2nd ed. *New York : Manning Publications*, 2021. 504 с. URL: <https://www.manning.com/books/deep-learning-with-python-second-edition> (дата звернення: 18.05.2026).
21. Salehin I., Kang D.-K. A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain. *Electronics*. 2023. Т. 12, № 14. С. 3106. URL: <https://doi.org/10.3390/electronics12143106> (дата звернення: 18.05.2026).
22. Review of deep learning: concepts, CNN architectures, challenges, and applications / L. Alzubaidi та ін. *Journal of Big Data*. 2021. Т. 8, № 1. С. 53. URL: <https://doi.org/10.1186/s40537-021-00444-8> (дата звернення: 18.05.2026).
23. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale / A. Dosovitskiy та ін. *Proceedings of the International Conference on Learning Representations (ICLR)*. Virtual, 2021. С. 1–21. URL: <https://openreview.net/forum?id=YicbFdNTTy> (дата звернення: 18.05.2026).
24. A survey of the recent architectures of deep convolutional neural networks / A. Khan та ін. *Artificial Intelligence Review*. 2020. Т. 53, № 8. С. 5455–5516. URL: <https://doi.org/10.1007/s10462-020-09825-6> (дата звернення: 18.05.2026).
25. Automated Damage Detection of Aircraft Surfaces Using Deep Learning and Transfer Learning / S. Cao та ін. *Applied Sciences*. 2022. Т. 12, № 18. С. 8972. URL: <https://doi.org/10.3390/app12188972> (дата звернення: 18.05.2026).
26. A survey of modern deep learning based object detection models / S. S. A. Zaidi та ін. *Digital Signal Processing*. 2022. Т. 126. С. 103514. URL: <https://doi.org/10.1016/j.dsp.2022.103514> (дата звернення: 18.05.2026).

27. Ultralytics YOLOv8 / G. Jocher та ін. *GitHub Repository*. 2023. URL: <https://github.com/ultralytics/ultralytics/> (дата звернення: 18.05.2026).
28. A comprehensive review of YOLO architectures in computer vision / J. Terven та ін. *Machine Learning and Knowledge Extraction*. 2023. Т. 5, № 4. С. 1680–1716. URL: <https://doi.org/10.3390/make5040083> (дата звернення: 23.05.2026).
29. Donecle. Automated Aircraft Inspection by Drones. *Donecle Official Website*. 2024. URL: <https://www.donecle.com/> (дата звернення: 23.05.2026).
30. Unmanned aerial vehicles and their use for aircraft inspection / М. Bugaj та ін. 2020 *New Trends in Civil Aviation (NTCA)*. *IEEE*, 2020. С. 45–50. URL: <https://doi.org/10.23919/NTCA50409.2020.9290929> (дата звернення: 23.05.2026).
31. Image Recognition Software, ML Image & Video Analysis - Amazon Rekognition - AWS. *Amazon Web Services, Inc.* URL: <https://aws.amazon.com/rekognition/> (дата звернення: 23.05.2026).
32. Cybersecurity challenges and cloud-based data processing in aviation: A systematic review / С. Lyskou та ін. *IEEE Aerospace and Electronic Systems Magazine*. 2023. Т. 38, № 4. С. 28–41. URL: <https://doi.org/10.1109/MAES.2023.3241512> (дата звернення: 23.05.2026).
33. *Roboflow Universe*. Aircraft-Surface-Damage Dataset. 2023. URL: <https://universe.roboflow.com/lemi-debele/aircraft-surface-damage/> (дата звернення: 25.05.2026).
34. Python 3.14 documentation. *Python documentation*. URL: <https://docs.python.org/3/> (дата звернення: 25.05.2026).
35. PyTorch Foundation. *PyTorch Documentation*. 2024. URL: <https://pytorch.org/docs/stable/> (дата звернення: 25.05.2026).
36. Home | Ultralytics Docs. *Ultralytics Docs*. URL: <https://docs.ultralytics.com/> (дата звернення: 25.05.2026).
37. OpenCV Team. *Open Source Computer Vision Library Documentation*. 2024. URL: <https://docs.opencv.org/> (дата звернення: 25.05.2026).
38. NumPy Developers. *NumPy Reference*. 2024. URL: <https://numpy.org/doc/stable/> (дата звернення: 25.05.2026).

- 39.Nsight Developer Tools. *NVIDIA Developer*. URL: <https://developer.nvidia.com/deep-learning> (дата звернення: 31.05.2026).
- 40.NVIDIA CUDA. *NVIDIA Developer*. URL: <https://developer.nvidia.com/cuda-zone> (дата звернення: 25.05.2026).
- 41.CUDA Deep Neural Network. *NVIDIA Developer*. URL: <https://developer.nvidia.com/cudnn> (дата звернення: 26.05.2026).
- 42.Real-time aircraft surface defect detection based on an improved YOLO network / Y. Wang та ін. *Aerospace Science and Technology*. 2022. Т. 124. С. 107543. URL: <https://doi.org/10.1016/j.ast.2022.107543> (дата звернення: 26.05.2026).
- 43.Convolutional Neural Networks for Automated Aircraft Surface Damage Detection / M. Talo та ін. *Aerospace*. 2021. Т. 8, № 10. С. 284. URL: <https://doi.org/10.3390/aerospace8100284> (дата звернення: 26.05.2026).
- 44.Generalized Focal Loss: Learning Qualified and Distributed Bounding Boxes for Dense Object Detection / X. Li et al. *Advances in Neural Information Processing Systems (NeurIPS)* / ed. by H. Larochelle et al. *Virtual*, 2020. Т. 33. С. 21002–21012. URL: https://proceedings.neurips.cc/paper_files/paper/2020/file/f0bda020d2470f2e74990a07a607ebd9-Paper.pdf (дата звернення: 26.05.2026).
- 45.Chicco D., Jurman G. The advantages of the Matthews correlation coefficient and F1-score over accuracy in computer vision metrics evaluation. *Scientific Reports*. 2020. Т. 10. С. 4837. URL: <https://doi.org/10.1038/s41598-020-61010-w> (дата звернення: 26.05.2026).
- 46.Automated Aircraft Structural Defect Detection Using Deep Learning and Computer Vision / R. E. Donatus та ін. *Mekatronika: Journal of Intelligent Manufacturing and Mechatronics*. 2025. Т. 7, № 2. С. 108–123. URL: <https://doi.org/10.15282/mekatronika.v7i2.11787> (дата звернення: 26.05.2026).

ДОДАТКИ

Додаток А

Програмні коди

Вихідний код, використаний у дослідженні, доступний у репозиторії GitHub: <https://github.com/sw3toff/Aviation-Damage-Detection> (дата звернення: 16.05.2026).

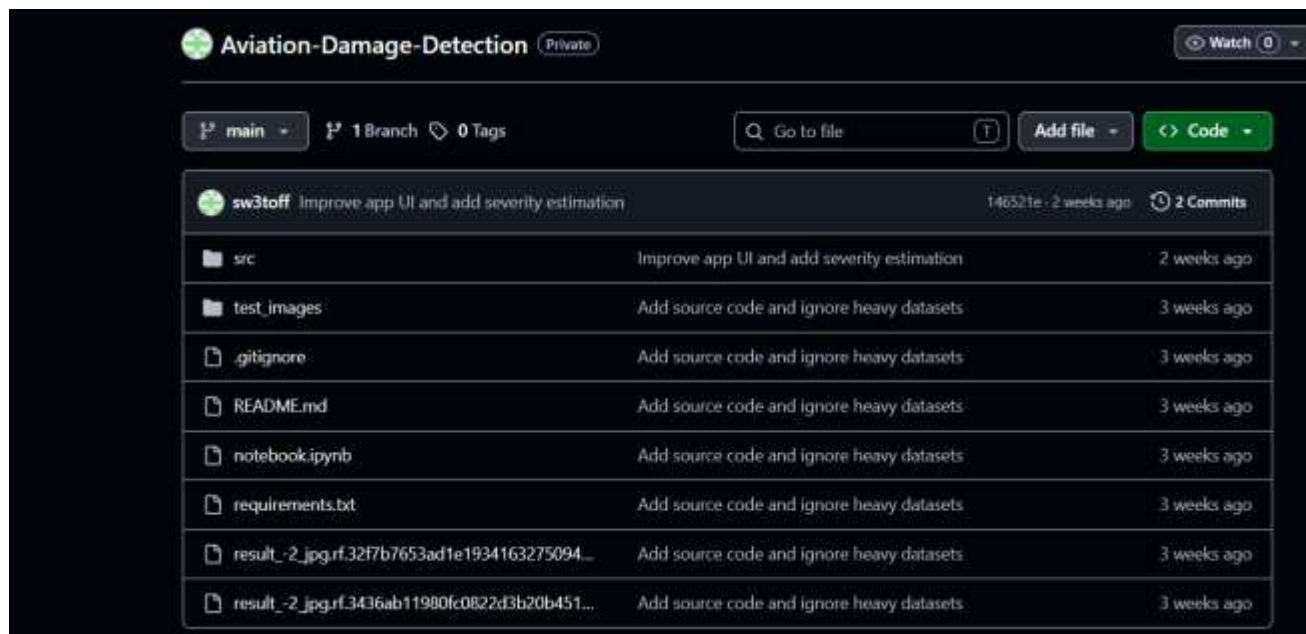


Рисунок В.1 – Головна сторінка репозиторію

Структура репозиторію наступна:

- модуль для інференсу й веб-інтерфейсу (*src/app.py*). Містить Gradio-додаток для завантаження зображень, передбачення дефектів моделлю YOLO, візуалізацію боксів, підготовку HTML-звіту та відображення підсумків;

- модуль для навчання моделі (*src/train.py*). Завантажує data.yaml, під'єднує предтреновану модель YOLO і запускає процес тренування з налаштуваннями аугментації, параметрами навчання та збереженням результатів;

- утиліта для оцінки тяжкості (*src/severity_analysis.py*). Потрібна *src/app.py* для перетворення класу дефекту і площі боксу в назву, кольорову мітку, числову оцінку та текстовий рівень тяжкості.

Додаток Б

Презентаційний матеріал

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

**МЕТОД НЕЙРОМЕРЕЖЕВОЇ ІДЕНТИФІКАЦІЇ СТУПЕНЯ
УРАЖЕННЯ АВІАЦІЙНОЇ ТЕХНІКИ ЗА АНАЛІЗОМ
ЗОБРАЖЕНЬ**



Виконав:
студент 4 курсу, групи КН-22-1
Чаузов Роман Русланович

Керівник:
доцент кафедри КН
Олекснадр Пасічник



Актуальність

Потужний розвиток цифровізації визначають радикальну зміну парадигми практичних рішень майже в усіх сферах життєдіяльності людини. У значній мірі це пов'язано із забезпеченням безпеки людей з жорсткими вимогами щодо часових параметрів, зокрема в авіаційному транспорті. Забезпечення безпеки польотів є пріоритетним завданням авіаційної галузі, що вимагає безперервного моніторингу технічного стану планера літака. На сьогодні основним способом виявлення пошкоджень залишається прямий візуальний огляд персоналом. Проте такий підхід критично залежить від людського фактора: втома інспектора, складні умови освітлення в ангарах та монотонність роботи створюють ризик пропуску критичних дефектів, таких як мікротріщини чи осередки корозії.

Об'єкт та предмет дослідження

- **Об'єкт дослідження:** процес ідентифікації поверхневих уражень авіаційної техніки на основі аналізу зображень.
- **Предмет дослідження:** методи та алгоритми нейромережевої обробки візуальної інформації для автоматизованого виявлення та класифікації дефектів авіаційної обшивки.

Мета та завдання дослідження

- **Мета роботи:** підвищення точності ідентифікації ступеня ураження авіаційної техніки шляхом розробки відповідного методу на основі глибокого навчання та алгоритмів детекції за аналізом зображень.
- **Завдання для досягнення мети:**
 - Провести огляд та аналіз сучасних методів комп'ютерного зору та детекції для задач ідентифікації дефектів авіаційної техніки.
 - Формалізувати задачу ідентифікації ступеня ураження авіаційної техніки.
 - Розробити метод ідентифікації ступеня ураження авіаційної техніки на основі глибокого навчання та алгоритмів детекції, орієнтований на підвищення точності.
 - Виконати програмну реалізацію розробленого методу.
 - Провести експериментальне дослідження методу з використанням метрик точності детекції.

Розділ 1. Характеристика предметної області

1. **Проблематика методів дефектоскопії:**
 - **Традиційні (Візуальний, НРК):** суб'єктивність (ризик пропуску 20-30% дефектів) та низька швидкість точкового сканування.
 - **Класичний комп'ютерний зір (CV):** детектори контурів та текстурні ознаки чутливі до заклепок та відблисків («семантичний розрив»).
 - **Хмарні AI-сервіси:** ризики конфіденційності даних та низька точність на специфічних авіаційних ураженнях.
2. **Аналіз існуючого ПЗ (на прикладі «Donecle»):**
 - **Концепція:** автономні БПЛА + «цифровий двійник» (3D CAD-модель).
 - **Переваги:** висока візуалізація та автоматичне формування звітів.
 - **Недоліки (бар'єри для впровадження):** закрита екосистема, висока вартість (сотні тисяч доларів) та неможливість роботи на пероні.

Інтерфейс виявлення дефектів у системі «Donecle»



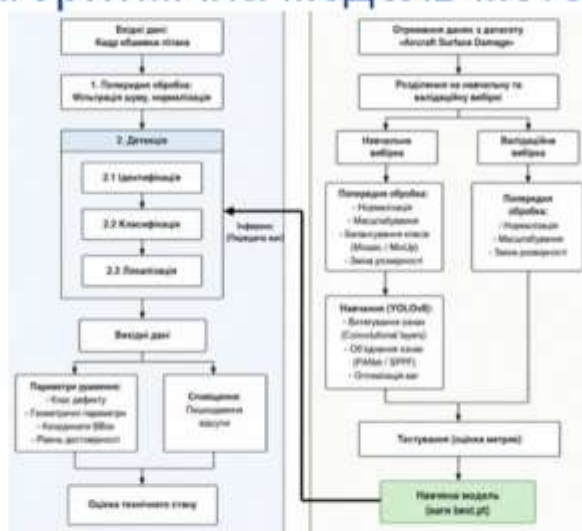
Висновок: існує потреба у локальній, незалежній системі, що поєднує точність сучасних мереж YOLO та доступний графічний інтерфейс для інженерів.

Розділ 2. Розробка методу нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень

Математична формалізація задачі ідентифікації

Назва етапу / компонента	Математичний вираз
Подання зображення у вигляді тривимірного тензора	$X \in \mathbb{R}^{W \times H \times C}$
Дискретна множина цільових класів дефектів	$K = \{, , '\}$
Вектор математичного опису виявленого дефекту	$y_i = \{x_i, y_i, w_i, h_i, p_i\}$
Функція відображення (нейромережевий інференс)	$\hat{Y} = F(X; \Theta)$
Задача навчання (оптимізація параметрів мережі)	$\Theta^* = \operatorname{argmin} \frac{1}{M} \sum_{j=1}^M L(F(X_j; \Theta), Y_{\text{true},j})$
Компонентний склад комплексної функції втрат	$L = \lambda_1 L_{CIoU} + \lambda_2 L_{BCE} + \lambda_3 L_{DFL}$

Алгоритмічна модель методу



Загальна схема методу

Розділ 3. Експериментальне дослідження методу

Програмна реалізація методу



Графічний інтерфейс розробленої інтелектуальної системи




Автоматично згенеровані результати детектування ушкоджень

Результати навчання нейронної мережі

Метрика	Навч. вибірка (Train)	Валідац. вибірка (Val)
Pre (Precision)	0.941	0.913
Rec (Recall)	0.865	0.815
m (F1-score)	0.901	0.861

Показники ефективності моделі на різних вибірках




Результати експериментального оцінювання моделі: а) гістограма порівняльного аналізу метрик на різних вибірках; б) матриця помилок (Confusion Matrix) розпізнавання класів дефектів

Аналіз результатів та порівняння з існуючими рішеннями

Метрика	Розроблений метод (YOLOv8)	Метод Mask R-CNN
Pre (Precision)	0.913	0.928
Rec (Recall)	0.815	0.887
m (F1-score)	0.861	0.907
M (mAP@0.5)	0.907	0.864

Порівняльний аналіз із існуючими методами детекції



Гістограма порівняльного аналізу метрик ефективності

Загальні висновки

У результаті виконання кваліфікаційної роботи бакалавра було успішно досягнуто поставлену мету - підвищення точності ідентифікації ступеня ураження авіаційної техніки шляхом розробки відповідного методу на основі глибокого навчання та алгоритмів детекції за аналізом зображень.

Для досягнення поставленої мети виконано наступні завдання:

- проведено огляд та аналіз сучасних методів комп'ютерного зору та детекції для задач ідентифікації дефектів авіаційної техніки;
- формалізовано задачу ідентифікації ступеня ураження авіаційної техніки;
- розроблено метод ідентифікації ступеня ураження авіаційної техніки на основі глибокого навчання та алгоритмів детекції;
- виконано програмну реалізацію методу;
- проведено експериментальне дослідження методу з використанням метрик точності детекції.

Загальні висновки

Виконано математичну формалізацію задачі ідентифікації ступеня ураження авіаційної техніки як задачі об'єктного детектування. Спроектовано алгоритмічну модель методу та алгоритм попередньої обробки зображень обшивки. Для реалізації методу обрано одностадійну згорткову нейронну мережу на базі архітектури YOLOv8 з аналітичним конвеєром: магістраль CSPDarknet53, модуль SPPF та розгалужена голівка передбачення. Підготовлено спеціалізований датасет на основі відкритого набору «Aircraft Surface Damage» (3405 зображень, три класи: тріщина, корозія, вм'ятина) з застосуванням методів аугментації Mosaic та MixUp. Визначено систему метрик оцінювання на основі IoU, Precision, Recall та mAP@0.5.

Виконано програмну реалізацію методу з використанням стеку технологій Python, PyTorch, Ultralytics та OpenCV з підтримкою GPU-прискорення (CUDA). Навчання моделі тривало 100 епох із застосуванням трансферного навчання та оптимізатора AdamW. За результатами експериментальних досліджень отримано: Precision - 0,913; Recall - 0,815; F1-score - 0,861; mAP@0.5 - 0,907. Порівняльний аналіз з архітектурою Mask R-CNN підтвердив перевагу розробленого методу за метрикою mAP@0.5 на 4,3%.



Anti-Plagiarism (<http://ap.km.ua>) v-16.718

Максимальне співпадіння з одним документом 2.0%

Словники перевірки: UA, US, RU. Помилки в документах: 14%

ID: 273370 Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень Додано в БД: 2026-06-03 Автора: Роман ЧАУЗОВ Керівники: Олександр ПАСІЧНИК Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	76971	663	3710 (5%)	57 (9%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

Протокол аналізу звіту подібності науковим керівником

Заявляю, що я ознайомився (-лась) з Повним звітом подібності, який був згенерований Системою виявлення і запобігання плагіату щодо роботи:

Автор: Роман ЧАУЗОВ

Співавтор:

Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень

Науковий керівник: Олександр ПАСІЧНИК, к.т.н., доц. каф. КН

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1: 4.48%

Коефіцієнт подібності 2: 2.08%

Мікропробіли: 0

Заміна букв: 1

Інтервали: 0

Білі знаки: 144

Дата створення звіту: 2026-06-03 21:49:49.0

Після аналізу Звіту подібності констатую наступне:

Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.

Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедур. Таким чином робота не приймається.

Обґрунтування:

2026-06-04

Дата

Петро Великий Р.В.

експерт

РІШЕННЯ ЕКСПЕРНОЇ КОМІСІЇ
КАФЕДРИ КОМП'ЮТЕРНИХ НАУК
ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Підтверджуємо ознайомлення з результатом звіту подібності щодо роботи, генерованого системою виявлення текстових збігів/ідентичності/схожості:

Назва: Метод нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень

Автор: Чаузов Роман Русланович

Освітня програма: Комп'ютерні науки

Рівень вищої освіти: Перший (бакалаврський)

Спеціальність: 122 - Комп'ютерні науки

Науковий керівник: к.т.н., доцент Пасічник Олександр Анатолійович

На основі аналізу кваліфікаційної роботи на дотримання вимог академічної доброчесності (у т.ч. відсутності ознак академічного плагіату) з урахуванням результатів перевірки роботи спеціалізованими програмними засобами комісія зробила такий висновок:

№	Висновок	Позначка про відповідність
1	Ознаки академічного плагіату	
1.1	Запозичення, виявлені в роботі, є законними і не є академічним плагіатом (далі зазначаються підстави віднесення запозичень до правомірних, якщо потрібно). Робота приймається до захисту.	<i>відповідає</i>
1.2	Виявлені запозичення не є академічним плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи (далі – зазначаються деталі та аргументовані підстави віднесення запозичень до правомірних). Робота приймається до захисту, але має бути відкоригована.	
1.3	Виявлені запозичення не є академічним плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота може бути допущена до захисту після того як буде відкоригована та дорацьована і успішно пройде повторну перевірку на академічний плагіат.	
1.4	Робота містить навмисні текстові спотворення, передбачувані спроби укріття текстових запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	
2	Інші види порушень академічної доброчесності	<i>відсутні</i>

Підтвердження:

Запозичення, виявлені в роботі Романа Чаузова, не є плагіатом, оскільки запозичення розміщені в розділі огляду існуючих підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; до запозичень входять фрагменти, які не мають авторства і містять поширені конструкції та загальновідомі терміни, скорочення. Рівень подібності не перевищує допустимої межі. Таким чином, робота є законною та приймається до захисту:

Обсяг запозичень, визначений системами виявлення збігів/ідентичності:

- за системою Anti-Plagiarism: 2,0 %;

- за системою StrikePlagiarism KPI1: 4,48%; KPI2: 2,08 %.

Завідувач кафедри КН

Гарант освітньої програми

Керівник кваліфікаційної роботи

Олександр БАРМАК

Олександр МАЗУРЕЦЬ

Олександр ПАСІЧНИК



**ВІДГУК НАУКОВОГО КЕРІВНИКА
на кваліфікаційну роботу бакалавра**

студента *гр. КН-22-1 Чаузова Романа Руслановича*

за темою *Метод нейромережової ідентифікації ступеня ураження авіаційної техніки за аналізом зображень*

1. Актуальність теми

Цифровізація змінює підходи до безпеки в авіації, де критично важливим є постійний моніторинг стану планера літака. Нинішній метод — візуальний огляд людиною — є неефективним через людський фактор (втома, погане освітлення), що створює ризик пропуску мікротріщин чи корозії. Автоматизувати цей процес і мінімізувати помилки дозволяють комп'ютерний зір та глибоке навчання. Створення методу на основі попередньої обробки зображень і згорткових нейромереж допоможе виявляти, класифікувати та оцінювати дефекти в реальному часі. Розробка такого методу є актуальною задачею комп'ютерних наук.

2. Відповідність роботи предметній області Стандарту спеціальності 122 Комп'ютерні науки

За стандартом, а саме описом предметної області, об'єктами вивчення та діяльності є математичні, інформаційні, імітаційні моделі реальних явищ, об'єктів, систем і процесів та методи і технології отримання, зберігання, обробки, передачі та використання інформації. Робота присвячена розробці методу нейромережової ідентифікації ступеня ураження авіаційної техніки за аналізом зображень та його програмній реалізації. При вирішенні поставленої задачі використано математичні моделі, методи та алгоритми розв'язання теоретичних і прикладних задач, що виникають відповідно до стандарту бакалавра спеціальності 122 – Комп'ютерні науки.

3. Професійні та особистісні якості бакалавра

При роботі над кваліфікаційною роботою бакалавра Чаузов Роман проявив себе кваліфікованим фахівцем та дисциплінованим студентом, вчасно виконуючи поставлені етапи дослідження. Як в процесі написання пояснювальної записки, так і при розробці прикладного програмного забезпечення проявив достатні для одержання успішного результату компетентності та результати навчання. Опанував професійні скіли за напрямком «Комп'ютерні науки» та достатньо значний софт скіл.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Одержані в роботі результати є наслідком особистої діяльності студента, який самостійно виконував всі поставлені задачі.

5. Ступінь оволодіння методами дослідження

При реалізації кваліфікаційної роботи показав достатній рівень компетентностей та володіння необхідними інструментами та обладнанням, методами, методиками та технологіями предметної області комп'ютерних наук.

6. Повнота та якість розкриття теми роботи

Тема роботи в повній мірі обґрунтована й розкрита, проведено аналіз актуальності та відомих досліджень в межах обраної теми, поставлені завдання, які у роботі виконані, та виконано програмну реалізацію.

7. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу

Структура роботи та послідовність викладення логічні та відповідають поставленій меті. Викладення матеріалу послідовне, аргументоване, літературно грамотне.

8. Можливість практичного застосування кваліфікаційної роботи бакалавра, окремих її частин

Розроблений у роботі метод та його програмна реалізація можуть бути використані для автоматизованої ідентифікації ступеня ураження авіаційної техніки фахівцями інженерних служб.

9. Висновок про можливість допуску кваліфікаційної роботи бакалавра до захисту, на яку оцінку заслуговує робота

Враховуючи високий рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка «відмінно».

Керівник



канд.техн.наук, доцент каф. КН Олександр ПАСІЧНИК



ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
МОН УКРАЇНИ



Кафедра комп'ютерних наук

РЕЦЕНЗІЯ

на кваліфікаційну роботу бакалавра

студента *гр. КН-22-1 Чаузов Роман Русланович*

за темою: Метод нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень

1. Актуальність обраної теми

Цифровізація трансформує підходи до безпеки в авіації. Головним завданням галузі є безперервний моніторинг технічного стану планера літака. Сьогодні основним методом виявлення пошкоджень залишається прямий візуальний огляд персоналом.

Проте цей підхід критично залежить від людського фактора. Втома інспекторів, складне освітлення в ангарах та монотонність роботи створюють високі ризики пропуску дефектів, як-от мікротріщин чи корозії. Це зумовлює гостру потребу в автоматизації аналізу візуальних даних. Використання комп'ютерного зору та глибокого навчання мінімізує суб'єктивні помилки. Розробка нових науково-практичних методів на основі згорткових нейромереж забезпечить точне виявлення та класифікацію руйнувань у реальному часі.

2. Повнота розкриття мети та завдань роботи

Мета роботи розкрита повністю, всі завдання виконані.

3. Зміст кожного розділу роботи

В першому розділі виконано аналіз сучасних підходів до вирішення завдань предметної області та сучасного стан. Визначено мету роботи та виконано постановку завдань. В другому розділі спроектовано метод нейромережевої ідентифікації ступеня ураження авіаційної техніки за аналізом зображень. Визначено критерії оцінки точності. В третьому розділі виконано експериментальне тестування методу та виконано оцінку точності ідентифікації.

4. Оцінка розробленої інформаційної системи, її практична цінність

Розроблений у роботі метод та його програмна реалізація можуть бути використані спеціалістами інженерно-авіаційної служби та техніко-експлуатаційних частин для підвищення ефективності ідентифікації уражень повітряних суден.

5. Якість оформлення кваліфікаційної роботи бакалавра

Структура роботи та послідовність викладення логічні та відповідають поставленій меті. Викладення матеріалу послідовне, аргументоване, літературно грамотне.

6. Недоліки кваліфікаційної роботи бакалавра

В роботі ідентифікуються ураження лише зовнішньої обшивки планера літака.

7. Загальний висновок (допускається чи не допускається до захисту), та оцінка на яку заслуговує кваліфікаційна робота.

Враховуючи рівень виконання та забезпечення усіх необхідних вимог, робота може бути

допущена до захисту. Рекомендована оцінка «відмінно».

Рецензент

Олександр ПЛІВОВАР, к.т.н., доц, доц. каф. ТМІТ, ХНУ