

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ
імені ІГОРЯ СІКОРСЬКОГО»
Приладобудівний факультет**

Кафедра автоматизації та систем неруйнівного контролю

«На правах рукопису»
УДК 004.895.32

До захисту допущено:

Завідувач кафедри

_____Юрій КИРИЧУК

«__»_____2023р.

Магістерська дисертація

на здобуття ступеня магістра

**за освітньо-науковою програмою «Комп'ютерно-інтегровані системи та
технології в приладобудуванні»**

**зі спеціальності 151 «Автоматизація та комп'ютерно-інтегровані
технології»**

**на тему: «Удосконалення алгоритмів сегментації зображень
поверхневих дефектів металевих виробів»**

Виконав:

Студент II курсу, групи ПК-11мн

Стешенко Ярослав Віталійович _____

Науковий керівник:

Професор, кандидат технічних
наук, доктор педагогічних наук,

Протасов Анатолій Георгійович _____

Консультант з розробки стартап-проекту:

д.е.н., доц., професор кафедри
економічної кібернетики

Шевчук Олена Анатоліївна _____

Рецензент:

Завідувач кафедри інформаційно-вимірювальних

технологій приладобудівного факультету д.т.н., професор

Єременко Володимир Станіславович _____

Засвідчую, що у цій магістерській
дисертації немає запозичень з праць
інших авторів без відповідних посилань.

Студент _____

Київ – 2023 року

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Приладобудівний факультет

Кафедра автоматизації та систем неруйнівного контролю

Рівень вищої освіти – другий (магістерський)

Спеціальність – 151 «Автоматизація та комп'ютерно-інтегровані технології»

Освітньо-наукова програма «Комп'ютерно-інтегровані системи та технології в приладобудуванні»

ЗАТВЕРДЖУЮ

Завідувач кафедри

_____Юрій КИРИЧУК

«___»_____2023 р.

ЗАВДАННЯ

на магістерську дисертацію студенту

Стешенку Ярославу Віталійовичу

1. Тема дисертації «Удосконалення алгоритмів сегментації зображень поверхневих дефектів металевих виробів», науковий керівник дисертації професор, кандидат технічних наук, доктор педагогічних наук кафедри АСНК Протасов Анатолій Георгійович, затверджені наказом по університету від «___»_____2023 р. №_____.
2. Термін подання студентом дисертації _____
3. Об'єкт дослідження: процес візуально-оптичної дефектоскопії виробів із металу.
4. Предмет дослідження: методи автоматизованого виявлення дефектів металу з використанням нейронних мереж.
5. Зміст пояснювальної записки: аналітичний огляд, теоретичний огляд, розробка програми, розробка стартап-проекту.
6. Орієнтовний перелік графічного матеріалу (ілюстративного): презентація (20 слайдів)
7. Орієнтовний перелік публікацій: 2 публікації.

8. Консультанти розділів дисертації*

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Розробка стартап-проекту	Шевчук Олена Анатоліївна, д.е.н., доц., професор кафедри економічної кібернетики КПІ ім. Ігоря Сікорського		

9. Дата видачі завдання: _____

Календарний план

№ з/п	Назва етапів виконання магістерської дисертації	Термін виконання етапів магістерської дисертації	Примітка
1	Аналіз сучасного стану систем візуально-оптичної дефектоскопії виробів та визначення напрямків їх удосконалення.	01.08.2022	Виконано
2	Аналіз існуючих методів сегментації зображень і розпізнаванням дефектів на зображеннях. Обґрунтування використання нейронних мереж для покращення якості детектування дефектів.	01.09.2022	Виконано
3	Розробка та вибір компонентів структурної схеми.	15.10.2022	Виконано
4	Розробка алгоритмічного та програмного забезпечення запропонованої автоматизованої системи аналізу зображень металевих поверхонь.	01.12.2022	Виконано
5	Проведення тестування на реальних даних та отримання кількісних оцінок якості роботи системи.	05.02.2022	Виконано
6	Розробка стартап-проекту	01.04.2023	Виконано
7	Формулювання висновків	05.05.2023	Виконано

Студент

Ярослав СТЕШЕНКО

Науковий керівник дисертації

Анатолій ПРОТАСОВ

* Якщо визначені консультанти. Консультантом не може бути зазначено керівника дипломного проєкту

РЕФЕРАТ

Магістерська дисертація складається із вступу, п'ятих розділів, загального висновку, списку використаної літератури та додатків. Дисертація містить 93 сторінки основного тексту, 37 ілюстрацій, 35 таблиць, було опрацьовано 52 джерела.

Актуальність теми. Виявлення дефектів завжди було і буде актуальною задачею. Несвоєчасне і недостатньо достовірне виявлення дефектів може призвести до незадоволення користувачів, втрати доходу, збільшення витрат, загрози безпеці та впливу на конкурентоспроможність організації. Поверхневі дефекти металевих виробів, такі як тріщини, плями, вм'ятини, корозія тощо, можуть негативно впливати на якість та міцність виробів. Розробка та застосування удосконалених алгоритмів сегментації дозволить вчасно виявляти потенційно небезпечні дефекти та приймати відповідні заходи для їх усунення, забезпечуючи безпеку та надійність виробів. Сегментація зображень поверхневих дефектів металевих виробів може бути використана для автоматизації процесу контролю якості виробництва. Автоматизована система виявлення дефектів дозволить зменшити залежність від роботи людини та підвищити швидкість та достовірність виявлення дефектів, що позитивно вплине на ефективність виробництва та знизить витрати. Для цього перспективно використовувати методи машинного навчання.

Мета роботи: автоматизація процесу сегментації зображень поверхневих дефектів металевих виробів отриманих в ході візуально-оптичної дефектоскопії із застосуванням нейромережових технологій.

Для реалізації мети необхідно виконати наступні завдання:

1. Проаналізувати сучасний стан розвитку методів виявлення поверхневих дефектів виробів із металу та визначити основні проблеми візуальної дефектоскопії. Визначити напрямки їх удосконалення.

2. Проаналізувати існуючі методи сегментації зображень з розпізнаванням дефектів на зображеннях. Обґрунтувати використання нейронних мереж для покращення якості детектування дефектів та вибрати необхідний тип мережі.

3. Розробити алгоритмічне та програмне забезпечення.
4. Провести тестування на реальних даних та отримати кількісні оцінки якості роботи системи.
5. Проаналізувати роботу системи з використанням різних бекбонів та різних порогів бінаризації масок.

Об'єкт дослідження: процес візуально-оптичної дефектоскопії виробів із металу.

Предмет дослідження: методи автоматизованого виявлення дефектів металу з використанням нейронних мереж.

Наукова новизна: Удосконалено алгоритми сегментації зображень поверхневих дефектів металевих виробів шляхом використання новітніх моделей нейронних мереж з глибинним навчанням, що дозволило підвищити достовірність автоматизованого виявлення дефектів.

Практична цінність: розроблено програмне забезпечення для автоматизованої сегментації дефектів та програмні алгоритми, які дозволяють автоматизувати цей процес та підвищити достовірність. Розроблено рекомендації щодо вибору бекбонів та порогів бінаризації масок.

ABSTRACT

The master's dissertation consists of an introduction, five chapters, a general conclusion, a list of references and appendices. The thesis contains 93 pages of the main text, 37 illustrations, 35 tables, and 52 sources.

Relevance of the topic. Detecting defects has always been and will always be an urgent task. Untimely and insufficiently reliable defect detection can lead to user dissatisfaction, loss of revenue, increased costs, safety hazards, and impact on the organization's competitiveness. Surface defects in metal products, such as cracks, stains, dents, corrosion, etc., can negatively affect the quality and durability of products. The development and application of advanced segmentation algorithms will allow you to detect potentially dangerous defects in time and take appropriate measures to eliminate them, ensuring the safety and reliability of products. Segmentation of images of surface defects in metal products can be used to automate the production quality control process. An automated defect detection system will reduce dependence on human work and increase the speed and reliability of defect detection, which will positively affect production efficiency and reduce costs. For this purpose, it is promising to use machine learning methods.

Purpose: to automate the process of segmentation of images of surface defects of metal products obtained during visual and optical flaw detection using neural network technologies.

To achieve this goal, the following tasks are necessary:

1. Analyze the current state of development of methods for detecting surface defects in metal products and identify the main problems of visual flaw detection. Identify areas for their improvement.
2. Analyze existing methods of image segmentation with image defect recognition. Justify the use of neural networks to improve the quality of defect detection and select the required type of network.
3. Develop algorithmic and software.
4. Conduct testing on real data and obtain quantitative estimates of the system's performance.
5. Analyze the system's performance using different backbones and different mask binarization thresholds.

Object of research: the process of visual and optical flaw detection of metal products.

Subject of research: methods of automated detection of metal defects using neural networks.

Scientific novelty: The algorithms for segmentation of images of surface defects of metal products have been improved by using the latest models of neural networks with deep learning, which has increased the reliability of automated defect detection.

Practical value: software for automated defect segmentation and software algorithms that automate this process and increase reliability have been developed. Recommendations for the selection of backbones and thresholds for mask binarization have been developed.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ.....	8
ВСТУП	9
РОЗДІЛ 1. АНАЛІТИЧНИЙ ОГЛЯД	11
1.1. Вибір та опис ОК	11
1.2. Огляд дефектів металевого прокату	11
1.3. Обґрунтування вибору методу контролю	18
1.4. Аналіз методів сегментації зображень	20
1.4.1. Сегментація на основі методу К-середніх.....	20
1.4.2. Порогова обробка (Thresholding)	20
1.4.3. Активні контури (Active contours)	22
1.4.4. Згорткові нейронні мережі.....	22
1.5. Огляд існуючих робіт	23
1.6. Постановка завдання	28
Висновки до розділу	29
РОЗДІЛ 2. РОЗРОБКА ПРОГРАМНО-ТЕХНІЧНИХ АЛГОРИТМІВ	30
2.1. Розробка структурної схеми системи	30
2.2. Підбір та опис відеокамер.....	31
2.3. Вибір джерела підсвічування.....	33
2.4. Вибір архітектури нейронної мережі.....	35
2.4.1. Fully Convolutional Network.....	35
2.4.2. DeepLab.....	36
2.4.3. LinkNet.....	37
2.4.4. U-Net.....	39
2.5. Розробка алгоритмів пост-опрацювання зображення.....	41
2.6. Розробка загального алгоритму роботи системи.....	44
Висновки до розділу	45
РОЗДІЛ 3. РОЗРОБКА І НАВЧАННЯ НЕЙРОННОЇ МЕРЕЖІ	46
3.1. Обґрунтування вибору модифікацій U-Net	46
3.1.1. U-Net++	46

3.1.2. DoubleU-Net.....	47
3.1.3. MultiResUNet.....	48
3.1.4. Доцільність використання базової моделі U-Net	49
3.2. Обґрунтування використання бекбону.....	50
3.2.1. VGG.....	50
3.2.2. DenseNets	51
3.2.3. ResNets	52
3.3. Опис середовища розробки.....	53
3.3.1. TensorFlow	53
3.3.2. Keras	54
3.3.3. Бібліотека Segmentation models	55
3.4. Опис навчального набору даних	55
3.5. Вибір метрик сегментації.....	57
3.6. Опис параметрів та результатів навчання.....	59
Висновки до розділу	59
РОЗДІЛ 4. ТЕСТУВАННЯ РОЗРОБЛЕНИХ АЛГОРИТМІВ.....	61
4.1. Оцінка результатів роботи системи на тестовій множині	61
4.2. Аналіз ефективності використання різних бекбонів.....	62
4.3. Аналіз впливу порогового рівня на розмір маски	63
4.4. Перспективні шляхи вдосконалення системи.....	65
Висновки до розділу	65
РОЗДІЛ 5. РОЗРОБКА СТАРТАП-ПРОЕКТУ «УДОСКОНАЛЕНІ АЛГОРИТМИ СЕГМЕНТАЦІЇ ЗОБРАЖЕНЬ ПОВЕРХНЕВИХ ДЕФЕКТІВ МЕТАЛЕВИХ ВИРОБІВ».....	67
5.1. Опис та технологічний аудит ідеї проєкту	67
5.2. Аналіз ринкових можливостей запуску стартап-проєкту	71
5.3. Розроблення ринкової стратегії розвитку.....	83
5.4. Розроблення маркетингової програми стартап-проєкту	86
Висновки до розділу	100
ВИСНОВКИ.....	102
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	104

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

ОК	—	об'єкт контролю;
НК	—	неруйнівний контроль
НМ	—	нейронна мережа;
ПЗ	—	програмне забезпечення;
ПК	—	персональний комп'ютер;
ОС	—	освітлення;
БВ	—	блок відеокамер;
ВМ	—	виконавчі механізми;
ЗНМ	—	згорткова нейронна мережа;
CNN	—	(Convolutional neural network) згорткова нейронна мережа;
FCN	—	(Fully Convolutional Network) повністю згорткова мережа;

ВСТУП

Розпізнавання дефектів є важливим етапом в будь-якому процесі виробництва та експлуатації продукту. Цей етап допомагає забезпечити якість виробу та надійність його роботи, а також знижує ризик негативних наслідків для користувачів та виробників.

Вироби із металу набули широкого поширення в різних областях застосування. Тому актуальним завданням є розпізнавання їх поверхневих дефектів, які можуть значно погіршувати якість та надійність виробу. Такі дефекти можуть стати завадою під час обробки або використання продукту, що може призвести до нештатних ситуацій та негативно вплинути на безпеку та здоров'я людей. Завчасне виявлення дефектів дозволяє проаналізувати причини їх виникнення і ввести відповідні зміни до процесів виробництва. Це допомагає покращити ефективність та економічність виробництва, а також знизити відсоток відходів. З метою покращення ефективності виявлення та розпізнавання дефектів, цей процес можна автоматизувати [1].

Існують різні методи контролю металевих поверхонь: візуальний, візуально-оптичний, вихрострумний, ультразвуковий, магнітопорошковий тощо. Однак, більш продуктивним з точки зору швидкості контролю є візуально-оптичний метод. Наприклад, у порівнянні з вихрострумним, візуально-оптичний метод контролю дозволяє одним знімком з камери контролювати велику площу об'єкта. Цей метод досить простий та дешевий у застосуванні, не вимагає спеціального обладнання та може бути застосований безпосередньо на лінії виробництва.

Є різні підходи до автоматизації [2] процесу розпізнавання дефектів на отриманих за допомогою камери зображеннях. Одним із них є детектування, тобто локалізація та класифікація дефекту шляхом обведення його у прямокутну рамку на зображенні. Однак, детектування не дозволяє достовірно визначити межі дефекту та не надає інформації про його площу, форму та інші параметри, що можуть бути важливими для подальшого аналізу.

Інший підхід використовує сегментацію зображень, що дозволяє більш достовірно ідентифікувати місце дефекту та відокремити його від бездефектної області об'єкту контролю. У результаті сегментації на зображення накладаються спеціальні маски, які відображають достовірні відбитки або контури виявлених дефектів. Маски або контури можуть бути зафарбовані різними кольорами, які відповідатимуть різним класам дефектів. Застосування сегментації може допомогти автоматизувати процес виявлення дефектів та знизити час, необхідний для аналізу великої кількості зображень. Це може бути особливо важливим в виробничих умовах, коли необхідно швидко та достовірно визначати наявність дефектів для забезпечення високої якості продукції.

Хоча існують різні методи для сегментації, але не всі з них дають можливість класифікувати виявлені об'єкти. Враховуючи бурхливий розвиток технологій глибинного навчання, для задач автоматизованої сегментації найбільш перспективним варіантом є використання нейромережевих моделей. Саме нейронні мережі на сьогоднішній день показують найкращі результати в області опрацювання зображень [3].

РОЗДІЛ 1. АНАЛІТИЧНИЙ ОГЛЯД

1.1. Вибір та опис ОК

Об'єктом контролю було вибрано металеві поверхні, так як вони дуже розповсюджені і виробів, які мають такі поверхні, дуже багато. Як приклад таких металевих поверхонь зручно розглядати контроль листів гарячого металевого прокату.

Металевий прокат – це один із найбільш поширених матеріалів, який застосовується в будівництві, машинобудуванні, виробництві різноманітних виробів і конструкцій. Завдяки своїм механічним характеристикам, металевий прокат здатний витримувати великі навантаження і має високу стійкість до корозії.

Контроль металевого прокату дозволяє виявляти можливі дефекти, які можуть виникати під час виробництва, зберігання та транспортування матеріалу. Також цей контроль дозволяє оцінити механічні характеристики матеріалу, які впливають на його здатність до витримування навантажень та стійкість до корозії.

Отже, об'єкт контролю металевого прокату є важливим з точки зору забезпечення якості та безпеки виробів і конструкцій, що ґрунтує його вибір для контролю.

Крім того, в процесі виробництва металевого прокату можуть виникати різноманітні дефекти, такі як тріщини, зарубки, випадки металу, неоднорідності в структурі та інші. Ці дефекти можуть впливати на якість та міцність металевого прокату, тому важливо проводити його контроль на кожному етапі виробництва.

1.2. Огляд дефектів металевого прокату

Інтелектуальна система повинна вміти класифікувати виявлені дефекти, для цього проведемо огляд можливих дефектів метал. Найчастіше можна зустріти такі поверхневі дефекти: розкатана тріщина, зливкова рванина,

розкатана бульбашка, бульбашка-здуття, зливкова пліва, розкатане забруднення та розшарування. Такі дефекти ще називають «дефекти сталеплавильного походження». Також є інші дефекти, які теж були розглянуті.

Розкатана тріщина (rolled crack) - це дефект (рис.1.1), який може виникнути на поверхні металевих виробів під час їх обробки розкатом. Такий дефект є наслідком поєднання механічної напруги та низької температури, які можуть зменшувати міцність матеріалу та призводити до тріщини. Може утворюватися внаслідок неоднорідності металу, що може виникати, наприклад, під час виробництва, переробки або складування [4].




Рисунок.1.1. Розкатана тріщина

Зливкова рванина (ingot hot tear) – це дефект (рис.1.2), який може виникнути при литті металевих виробів, коли залитий метал затвердів нерівномірно. У результаті утворюється розлом або тріщина в зоні зливу. Її утворення пов'язане з тим, що при литті металу, залиття поступово охолоджується та з тим, що залитий метал зазнає зміни об'єму, що може приводити до появи напруг у зоні зливу.




Рисунок.1.2. Зливкова рванина

Розкатана бульбашка (rolled blister) – це дефект (рис.1.3), який може виникати на поверхні металевих виробів під час їх обробки розкатом. Цей дефект має вигляд вигнутої в середину пухкої ділянки, що схожа на бульбашку.

Утворюються через затримки газів, що знаходяться в металевому матеріалі, під час процесу розкату.



Рисунок.1.3. Розкатана бульбашка

Бульбашка-здуття – це дефект металевого виробу (рис.1.4), який представляє собою округлу порожнину або випуклість на поверхні матеріалу. Цей дефект може мати різні розміри та глибину і може виникати як в результаті процесу виробництва, так і під час експлуатації виробу.

Утворення бульбашок-здуттів зазвичай пов'язане з процесом виробництва матеріалу, коли в металі під час його затвердіння залишається недостатньої кількості розчиненого газу або інших інородних включень. Коли цей газ або інородна речовина виходять на поверхню матеріалу, вони можуть створювати бульбашку-здуття.




Рисунок.1.4. Бульбашка-здуття

Зливкова пліва (rolled slab, sliver) – це дефект металевих виробів (рис.1.5), який виникає при литті металу в зливки. Цей дефект представляє собою тонкий шар матеріалу, який формується на поверхні зливка і може відокремлюватись від основного металу. Зливкова пліва може впливати на якість виробу, особливо якщо вона знаходиться в критичних місцях.

Зливкова пліва утворюється в результаті процесу лиття, коли поверхня розплавленого металу знаходиться у контакті з повітрям або іншими речовинами, які можуть утворювати хімічні реакції з металом. Найчастіше зливкова пліва утворюється на поверхні зливка з низькотемпературних сплавів,

таких як алюміній та його сплави, оскільки ці сплави швидко реагують з киснем повітря та іншими газами.




Рисунок.1.5. Зливкова пліва

Розкатане забруднення (rolled slag patch) – це дефект (рис.1.6), який утворюється на поверхні металевої стрічки або пластини під час процесу виробництва. Цей дефект представляє собою тонку шаровидну включену структуру, яка може мати різні розміри та форми. Розкатане забруднення утворюється через нестачу здатності розчинення забруднень у металі під час виробничого процесу.



Рисунок.1.6. Розкатане забруднення

Лускатість (чешуйчатість, rippled surface) є одним з дефектів металевих поверхонь (рис.1.7), коли на поверхні металу утворюються хвилеподібні згорблення або вироги. Цей дефект може виникнути під час обробки поверхні металу, зокрема під час фрезерування, гартування або при обробці різцем. Однією з головних причин виникнення лускатості є неправильний процес обробки, наприклад, надмірне навантаження на різець або фрезу, що може призвести до перегріву поверхні металу та виникнення хвилеподібних згорблень.



Рисунок.1.7. Лускатість

Тріщина напруження (stress crack) – це дефект в металевому виробі (рис.1.8), який утворюється під впливом напружень і може призвести до руйнування виробу. Такі тріщини зазвичай утворюються на поверхні виробу або в глибині матеріалу, під впливом змін напружень. Це може статися, наприклад, при згинанні або розтягуванні виробу, якщо матеріал має низьку міцність або не витримує деяких фізичних властивостей.




Рисунок.1.8. Тріщина напруження

Деформаційна рванина, також відома як "гарячі сльози" або "hot tears" – це дефект, який може виникнути при литті металевих виробів з високотемпературних сплавів (рис.1.9). Утворення деформаційної рванини пов'язане з нерівномірним зміцненням металу під час охолодження, що може спричинити розриви в місцях з високими напруженнями. Коли метал розплавляється і заливається в форму, він охолоджується і зміцнюється, звужуючись в процесі охолодження.




Рисунок.1.9. Деформаційна рванина

Прокатана плівка (rolling skin) – це тонкий шар металу, який з'являється на поверхні металевій заготовки під час процесу прокатки (рис.1.10). Цей шар

металу може бути різного розміру та форми. Він може мати вигляд білої або сірої плівки, яка перебуває на поверхні заготовки, або може виявлятися під верхнім шаром металу, який відокремлюється під час деформації. Утворення прокатаної плівки пов'язане з взаємодією між металом та поверхнею валків під час процесу прокатки.




Рисунок.1.10. Прокатана плівка

Риска (англ. guide mark) – це дефект на поверхні металевого виробу, що являє собою видиму лінію або паз, який може бути прямим або довільної форми (рис.1.11). Утворення рибок пов'язане з різними причинами, такими як нестача мастила на валках, що викликає зношування або перегрівання валків, нерівності на поверхні валків, неправильно настроєні машини та обладнання, а також неправильне виконання технологічного процесу виробництва.




Рисунок.1.11. Риска

Вкатана окалина (rolled-in scale) – це дефект, який зазвичай зустрічається на поверхні металевих виробів після процесу гарячої прокатки (рис.1.12). Цей дефект утворюється, коли окалина або інші забруднення потрапляють між валками під час процесу прокатки та залишаються між поверхнею виробу та валками. Під час подальшої прокатки ці забруднення стискаються та вкатуються в структуру металу, утворюючи тонку плівку на поверхні виробу. Ця плівка може бути гладкою або нерівною та може знижувати якість поверхні виробу. Для уникнення утворення вкатої окалини важливо забезпечити

належне очищення поверхні виробу та валків перед початком процесу прокатки.




Рисунок.1.12. Вкатана окалина

Рябизна (pitted surface) – це дефект поверхні металевої заготовки, при якому на поверхні утворюються ямки або отвори різного розміру та глибини (рис.1.13). Може утворюватися під час виробничих процесів, таких як гартування, прокатка або ковання, коли на поверхні металу утворюються мікротріщини або мікропори. Ці мікротріщини та мікропори можуть бути результатом недостатньої обробки поверхні металу, низької якості матеріалу або неправильного процесу виробництва.



Рисунок.1.13. Рябизна

Раковина-вдав (shrinkage cavity) – це тип дефекту, що виникає при затвердінні рідкого металу або сплаву (рис.1.14). Раковина-вдав утворюється, коли затверділий метал скорочується під час охолодження, але через недостатню кількість рідини в литому металі не може бути заповнена, що призводить до утворення порожнини в матеріалі.



Рисунок.1.14. Раковина-вдав

Відбитки (roll marks або indentations) – це дефекти, що можуть виникати при виробництві металевих виробів під час процесу прокатки (рис.1.15). Вони представляють собою глибокі ямки, які знаходяться вздовж поверхні металу і зазвичай знаходяться в паралельних рядках. Утворення відбитків пов'язане з неоднаковим надходженням матеріалу в прокатний станок, що призводить до зміни напружень в матеріалі. Якщо ці напруження перевищують межу міцності металу, то відбувається деформація поверхні металу, і утворюються відбитки.




Рисунок.1.15. Відбитки

1.3. Обґрунтування вибору методу контролю

Існують різноманітні методи контролю металевих поверхонь, залежно від конкретної задачі, типу дефектів, матеріалу та багатьох інших факторів. Деякі з найпоширеніших методів включають [5]:

1. Візуальний контроль – перевірка візуальної зовнішності поверхні на наявність дефектів, таких як тріщини, плями, сколи та інші.
2. Візуально-оптичний метод – це метод контролю, який може використовувати спеціальні камери для візуального огляду поверхні виробу.
3. Магнітно-порошковий контроль – застосування магнітного поля для виявлення дефектів, таких як тріщини та підварні дефекти.
4. Ультразвуковий контроль – застосування ультразвукових хвиль для виявлення дефектів, таких як тріщини та вміст порожнин.
5. Рентгенівський контроль – використання рентгенівських променів для виявлення внутрішніх дефектів, таких як пузири та тріщини.
6. Електромагнітний контроль – використання електромагнітних полів для виявлення дефектів, таких як тріщини та підварні дефекти.

7. Контроль твердості – вимірювання твердості поверхні для виявлення змін в структурі та можливих дефектів.
8. Хімічний аналіз – використання хімічних тестів для визначення складу матеріалу та виявлення можливих дефектів, таких як корозія та окислення.
9. Теплові методи, такі як термографія, що використовують інфрачервоне випромінювання для виявлення дефектів та аномалій в температурі [6, 7, 8].

Візуально-оптичний метод дозволяє детально оглянути поверхню та виявити різноманітні дефекти, такі як тріщини, корозію, розкатані забруднення, відбитки, підтяжки та інші. Камери, що використовуються для, можуть мати різну конфігурацію, наприклад, оптичні зум-камери, ендоскопи або високошвидкісні камери. Залежно від вимог до контролю, використовуються різні типи камер та обладнання для запису зображення.

Цей метод може бути застосований для контролю виробів під час виробництва або після завершення процесу виготовлення для виявлення потенційних проблем та забезпечення якості виробу. Він є швидким, надійним та ефективним методом контролю, який дозволяє знизити витрати на контроль виробів та забезпечити високу якість продукції.

Наприклад, вихрострумний методом досить складний та дорогий у застосуванні. Він вимагає використання спеціального обладнання, такого як вихрострумові датчики, та кваліфікованих спеціалістів для його застосування. Крім того, вихрострумний метод зазвичай застосовують для контролю обмеженої області на поверхні об'єкта, тому для контролю великої площі об'єкта потрібно проводити багато сканувань, що займає багато часу. У порівнянні з вихрострумним методом, візуальний метод контролю якості дозволяє одним знімком з камери контролювати велику площу об'єкта. Цей метод було обрано, так як він досить простий та дешевий у застосуванні, не вимагає спеціального обладнання та може бути застосований безпосередньо на лінії виробництва.

1.4. Аналіз методів сегментації зображень

Сегментація зображень є процесом розподілу пікселів на зображенні у групи, які відповідають різним об'єктам або регіонам на зображенні. Цей процес є важливим етапом в багатьох задачах обробки зображень, включаючи виявлення поверхневих дефектів металевих виробів.

1.4.1. Сегментація на основі методу К-середніх

Метод К-середніх (K-Means) є одним з найпоширеніших методів кластерного аналізу. Він використовується для групування набору даних у певну кількість кластерів.

Опис методу K-Means:

1. Вибирається кількість кластерів K , яку користувач повинен задати.
2. Вибираються початкові центроїди кластерів. Центроїда - це фіктивна точка, яка представляє центр кожного кластеру.
3. Кожна точка даних призначається до найближчої центроїди.
4. Для кожної центроїди обчислюється нове середнє значення, використовуючи всі призначені до неї точки даних.
5. Кроки 3 і 4 повторюються до тих пір, поки центроїди не стабілізуються або досягнута максимальна кількість ітерацій.

Проте алгоритм K-Means дуже чутливий до шуму та викидів у дані. Вони можуть вплинути на центроїди та призвести до неправильної кластеризації. Визначення оптимальної кількості кластерів (K) може бути складною задачею. Неправильний вибір K може призвести до некоректної кластеризації або до втрати корисної інформації. Коли маємо категоріальні дані, наприклад, вектор з мітками, метод K-Means може бути менш ефективним, оскільки він використовує евклідову відстань, що передбачає числові значення.

1.4.2. Порогова обробка (Thresholding)

Метод порогової обробки – це один з найпростіших і найбільш поширених методів сегментації зображень, який полягає в розділенні пікселів

на дві групи на підставі порогового значення. Основна ідея полягає в тому, що пікселі зі значенням, яке більше порогового значення, відносяться до однієї групи, а пікселі зі значенням, яке менше порогового значення, відносяться до іншої групи.

Метод порогової обробки може бути використаний для сегментації зображень з різними дефектами, такими як плями, викиди, лінії, контури та інші. Підбір оптимального порогового значення є важливим кроком для досягнення найкращих результатів.

Процес порогової обробки можна описати наступними кроками:

1. Завантажити зображення та перетворити його в відтінки сірого.
2. Вибрати підходящий пороговий рівень або порогове значення. Це може бути зроблено, наприклад, за допомогою аналізу гістограми зображення.
3. Застосувати поріг до зображення шляхом перевірки кожного пікселя. Якщо значення пікселя більше порогового значення, то піксель входить до однієї групи, в іншому випадку – до іншої групи.
4. Застосувати додаткові операції для покращення результатів сегментації, якщо необхідно. Наприклад, можна використовувати операції морфологічної обробки, щоб видалити невеликі області або залити малі отвори.
5. Зберегти результати сегментації в вигляді чорно-білого зображення, де білі пікселі відповідають одній групі, а чорні пікселі – іншій групі.

Метод порогової обробки має свої недоліки. Наприклад, він може не давати задовільних результатів для зображень з високим контрастом або з дефектами, що не мають чітких контурів. Крім того, підбір оптимального порогового значення може бути складним і вимагати експертного досвіду.

У практиці метод порогової обробки може бути застосований як самостійний метод сегментації, або як один з етапів складніших алгоритмів сегментації, таких як метод кластеризації або методи активних контурів.

1.4.3. Активні контури (Active contours)

Метод активних контурів, відомий також як метод змінних форм, є одним з методів сегментації зображень. Цей метод використовує контур, який "розтягується" по зображенню та змінює свою форму залежно від властивостей зображення.

У методі активних контурів спочатку створюється контур навколо області зображення, яка містить об'єкт, що потрібно відокремити. Контур є замкнутою кривою, яка представляється математичною формулою. Потім контур "розтягується" по зображенню, змінюючи свою форму та розташування в напрямку градієнту яскравості зображення. Цей процес повторюється доти, доки контур не співпаде з реальним контуром об'єкта.

З недоліків можна виділити наступні: чутливість до початкових значень, не підходить для складних форм об'єктів, може витратити багато часу, складне налаштування параметрів, може давати погані результати при обробці зображень з високим контрастом.

1.4.4. Згорткові нейронні мережі

Метод сегментації зображень за допомогою згорткових нейронних мереж (Convolutional Neural Networks, CNN) є одним з найефективніших методів для автоматизованої сегментації зображень. Згорткові нейронні мережі є нейромережевими архітектурами, які здатні визначати значення функцій на основі локальних областей вхідного зображення, їх називають ядрами або фільтрами.

Основна ідея полягає у використанні набору згорткових прошарків, які використовуються для виділення низькорівневих ознак зображення, таких як краї та текстури. Ці низькорівневі ознаки потім передаються в більш глибокі прошарки мережі, де вони комбінуються для виділення високорівневих ознак, які можуть бути використані для класифікації об'єктів на зображенні або для сегментації.

CNN дозволяє отримувати високу достовірність в порівнянні з традиційними методами сегментації зображень. Можуть працювати з великими наборами даних і здатні ефективно навчатись зображенням за допомогою глибокого навчання. Можуть автоматично вибирати найбільш релевантні ознаки зображення для сегментації, що робить цей метод більш ефективним за традиційні методи. Можуть використовуватись для різних задач обробки зображень, таких як класифікація, детектування об'єктів та сегментація.

Але CNN вимагають великої кількості обчислювальних ресурсів, що може бути проблемою для використання на старіших апаратах або при обробці великого обсягу зображень. Потребують великої кількості навчальних даних, що може бути складно зібрати для певних застосувань.

У будь-якому випадку, згорткові нейронні мережі залишаються дуже потужним інструментом для задач сегментації зображень, що дозволяють досягати високої достовірності та швидкості роботи.

1.5. Огляд існуючих робіт

У роботі [9] автори розглядають автоматичну систему контролю поверхні (ASIS), яка включає: дві цифрові лінійні відеокамери для зйомки верхньої та нижньої поверхні плоскої заготовки, блок підсвічування верхньої та нижньої поверхні плоскої заготовки, комп'ютерне обладнання. Описується система, яка забезпечує 100% контроль поверхні прокату (верхньої та нижньої сторін) автоматично виявляє та класифікує дефекти листового металу в режимі реального часу та була вперше встановлена на виробництві в домашніх умовах в 2003 році на гарячій прокатці 2000 JSC «Новолипецький металургійний комбінат» (НМК). Увесь асортимент заводу 2000 був розподілений на п'ять груп за зовнішнім виглядом поверхні. Після проведення гарантійних випробувань продовжувалися роботи з ідентифікації дефектів гарячекатаного металу та розширення бази даних знань ASIS. Більше 10 тисяч зображень дефектів були додані до бази даних протягом року.

Така система є доволі дорогою та складною в налаштуванні. Треба ділити

асортимент прокатних сталей на групи за зовнішнім виглядом, визначати в системі порогову оцінку контрасту виявлення дефектів та створювати файл класу. Це все займає часу і вимагає вмінь користувача.

У статті [10] пропонується метод, який може бути використаний онлайн на кожній деталі безпосередньо на лінії виробництва. Система використовує метод дефлектометрії одного знімка в інфрачервоному діапазоні. На достатньо довгих довжинах хвиль поверхня листового металу стає дзеркальною, що дозволяє використовувати метод дефлектометрії. Для цього методу було розроблено пристрій, який може відображати референсний шаблон на інфрачервоних довжинах хвиль. Цей один інфрачервоний референсний шаблон відбивається від поверхні сировинного аркушного металевого об'єкта, а відбите зображення захоплюється термокамерою. Деформація відбитого шаблону через геометрію та дефекти поверхні аналізується методом Фур'є-перетворення. Через метод одного знімка вібрації під час вимірювання не перешкоджають, і проблема вирівнювання, яка є характерною для методів з кількома знімками, в цьому випадку відсутня.

Однак метод дефлектометрії зазвичай обмежений застосуванням до досить малих деталей, так як для більших розмірів необхідно мати велику кількість ресурсів, щоб провести точні вимірювання. Достовірність дефлектометрії може бути обмежена через шум, що виникає під час зчитування даних та залежить від якості приладу, технології виготовлення та якості матеріалу. Цей метод може показати, що є дефект на поверхні, але не завжди можливо визначити його тип та розмір, що може зробити процес виявлення та корекції дефектів більш складним.

У роботі [11] пропонується новий метод визначення та приблизної локалізації дефектів поверхні сталевих стрічок на основі розкладу на одиночні значення (Singular Value Decomposition). Метод не потребує сегментації зображення. Матриця сірих відтінків цифрового зображення проєктується на одиночні вектори, отримані за допомогою розкладу на одиночні значення. Дефект відображається як раптова зміна в проєкціях. Тому дефекти можна

визначити та приблизно локалізувати згідно з раптовими змінами. Експериментальні результати свідчать про те, що цей метод є дійсним та зручним для прямого визначення дефектів поверхні.

Із занадто великими дефектами або занадто великою кількістю розсіяних дефектів на зображеннях цей метод стає менш задовільним. Крім того, при дуже нерівномірному освітленні зображення дає незадовільні результати. Наприклад, світло, сфокусоване на одній точці, може викликати помилкову тривогу, оскільки світлова пляма може розглядатися як дефект. Виявлені форма та площа є недостовірними, кількість виявлених дефектів перевищує реальну кількість.

Авторами роботи [12] була розроблена експериментальна система контролю металевого прокату, здатна роботи в режимі реального часу в умовах виробництва. Використовується візуально-оптичний метод контролю. Схема підсвічування виробу може бути налаштована для оптимізації контрасту різних дефектів, залежно від шорсткості поверхні базового матеріалу та дефектів. Добре функціонування освітлення та особливо його підтримка в розпізнаванні дефектів значно спростили алгоритми аналізу зображень. Розпізнавання дефектів базується на аналізі блобів(від англ. «blob» – binary large object) в зображеннях. Авторами встановлено, що процес класифікації із використанням статистичних методів ускладнений великими варіаціями різних типів дефектів та відсутністю достовірних моделей для їх форми. Класифікація більших за площею дефектів, таких як поздовжні і поперечні подряпини, працює добре. Але система не надійна для дефектів, що складаються з декількох дрібних дефектів, наприклад, розливів. Також, недоліком всіх статистичних методів є низька стійкість до завад, низька універсальність та погані узагальнюючі властивості.

У статті [13] запропоновано новий підхід, спрямований на підвищення надійності результатів сегментації корозійних пошкоджень за допомогою традиційних методів. Негативний вплив на результати сегментації чинить нерівномірне освітлення, подібне до кольорів корозії захисне покриття, а також

наявність корозійних плям. Кожен з цих факторів може спричинити пере- або недосегментацію області корозійних пошкоджень. Авторами запропонований інтелектуальний алгоритм цифрової обробки зображень для сегментації дефектів корозії на пофарбованих сталевих поверхнях. Після попередньої обробки зображення застосовується процедура альфа-матування. Ця процедура використовує сегментацію з моделлю змішування за Гауссом.

Запропонований метод створює видимі спотворення зображення навколо меж тіней. Подібна проблема виникає при виявленні корозійних плям за допомогою альфа-матування. Ця проблема частково вирішується вибором деяких порогових значень. Але такий підхід ефективний лише для невеликих областей зображення, оскільки різні ділянки зображення можуть вимагати різних порогових значень для правильної сегментації. Крім того, запропонований метод виявлення корозії на червоному фоні має високу ймовірність помилки для зображень, які містять лише корозійні або лише непошкоджені області.

В роботі [14] пропонується використання технологій комп'ютерного бачення для виявлення дефектів поверхонь з металу. Підхід використовує архітектуру глибоких згорткових нейронних мереж для сегментації. Загальна модель сегментації використовує різні техніки попередньої підготовки та післяобробки зображення для оптимізації алгоритму, щоб зробити його зручним для практичного використання. Система достовірно сегментує дефектні області та має достовірність класифікації на рівні 93.46%, навіть якщо зображення містять багато спотворень. Якісний та кількісний аналіз підтверджують продуктивність алгоритму. Іншою перевагою запропонованої моделі є те, що її можна легко переробити для вирішення схожих проблем сегментації інших об'єктів за допомогою незначних модифікацій алгоритму.

Водночас, розглянута система призначена для сегментації зображень лише одного типу дефектів – металевих тріщин. Це є недоліком, оскільки часто треба виявляти та класифікувати більше одного дефекту. Тому існує потреба розробки такої нейронної мережі, яка буде здатна сегментувати зображення з

декількома різними типами дефектів.

Автори дослідження [15] для вирішення проблеми детектування нетипових дефектів запроваджують ієрархічний метод для класифікації та виявлення дефектів сталевих поверхонь. Запропонований підхід використовує ієрархічну структуру розподілу об'єктів на два класи на першому етапі, та алгоритми виявлення об'єктів та семантичної сегментації на другому етапі. Він демонструє середню достовірність (mAP) 77,12% у виявленні поверхневих дефектів.

Приклад результату детектування та створена карта дефектів на тестових даних наведені на рисунку 1.16. На рисунку можна побачити вхідне зображення, відповідну йому ground truth (GT) анотацію, тобто правильні відповіді на вхідне зображення, та кінцеве передбачене нейронними мережами зображення. Схожість передбаченого зображення з GT анотованим очевидна. Також, модель змогла виявити слабкі подряпини, хоча анотація не надавала інформацію про них.




Рисунок.1.16. Виявлення дефектів у вигляді подряпин: а – вхідне зображення; б – анотація вхідного зображення; с – зображення на виході системи

Недоліком даної розробки є те, що класифікація і сегментація виконуються двома окремими нейронними мережами. Така архітектура ускладнена, оскільки замість однієї мережі потрібно навчати дві. Це значно знижує адаптивність системи та вимоги до навчального набору даних. Окрім того, автори вказують на те, що деякі дефекти все ще не вдається виявити, оскільки різниця між дефектом і фоном є нечіткою. Виявлення дефектів також

ускладнене недоліком обраної архітектури мережі для детектування, а саме обмеженим набором anchor-boxes.

Отже, актуальним завданням є удосконалення методу сегментації зображень дефектів металевих поверхонь. Зокрема, перспективним є використання однієї нейронної мережі, архітектура якої буде позбавлена розглянутих в ході аналітичного огляду недоліків.

1.6. Постановка завдання

На основі огляду існуючих робіт було виявлено, що вже є системи, які призначені для візуально-оптичного контролю металевих поверхонь. Також, вже є автоматизовані системи, які вміють виявляти дефекти, класифікувати їх і навіть робити сегментацію зображень цих дефектів. Але вони усі мають певні обмеження та недоліки, тому актуальним завданням є вдосконалення алгоритмів автоматизованої сегментації зображень поверхневих дефектів металевих поверхонь. Така система повинна в автоматизованому режимі виявляти місцезрештування дефектів, визначати їх контури та проводити класифікацію за типом. Вхідні зображення об'єкту контролю повинні надходити до блоку інтелектуального цифрового опрацювання зі спеціальної камери, встановленої на виробничій лінії або безпосередньо над виробом.

Під час звичайного виробництва робоча швидкість поверхні, що перевіряється, зазвичай висока. Для плоских сталевих виробів швидкість у кінці прокатки, де має працювати контрольне обладнання, зазвичай становить 20 м/с. Для довгих виробів, зокрема дроту, швидкість може досягати 100 м/с [16]. Робота в режимі реального часу з такою високою швидкістю вимагає спеціального обладнання для обробки зображень і програмного забезпечення з малим часом виконання. Камера повинна мати високу роздільну здатність та бути розташованою на такій відстані від ОК, щоб вона могла покривати як можна більшу площу і при цьому не втрачала здатність розрізняти дефекти малого розміру. В якості додаткового підсвічування треба використовувати світлодіодну стрічку. Контролюватися ОК

буде після прокатки, тобто після охолодження в холодильниках.

Затребуваним видом листового прокату є сталевий лист. Товщина листів від 0.5 мм до 2.5 мм, ширина – від 710 мм до 1800 мм. Довжина листа в межах від 2 - 3,5 м. Набір системи перевірки повинен складатися з 3–4 камер, які покривають всю ширину смуги. Для довгих сталевих виробів кілька камер повинні бути розташовані периферійно, щоб забезпечити охоплення всієї поверхні. На виході системи повинно отримуватися зображення із виділеними контурами виявлених дефектів. Колір контуру повинен відповідати певному класу (типу) дефекту.

Обмеження технічної можливості системи для виявлення поверхневих дефектів на металевому прокаті включають роздільну здатність камери, чутливість та достовірність виявлення дефектів, швидкість обробки даних.

Висновки до розділу

В першому розділі металеві поверхні було вибрано та описано в якості об'єкту контролю. Проведено огляд різних можливих дефектів металевого прокату. Обґрунтовано вибір методу контролю та проаналізовано різні методи сегментації зображень.

Виходячи з приведенного огляду існуючих робіт, перспективними є методи сегментації, які базуються на глибинному навчанні. Розроблені алгоритми автоматизованої сегментації повинні мати не меншу ефективність та достовірність роботи, ніж існуючі аналоги. Система має бути позбавлена розглянутих раніше архітектурних обмежень та бути гнучкою і зручною для практичного використання в промислових умовах.

РОЗДІЛ 2. РОЗРОБКА ПРОГРАМНО-ТЕХНІЧНИХ АЛГОРИТМІВ

2.1. Розробка структурної схеми системи




Рисунок.2.1. Структурна схема вимірювального каналу

ОС – освітлення, ОК – об’єкт контролю, Бв – блок відеокамер, ВМ – виконавчі механізми, ПК – персональний комп’ютер

Після включення виконавчого механізму об’єкт контролю займає певну позицію для початку проведення контролю. За допомогою блоку освітлення та відеокамер отримується зображення ОК, яке передається на персональний комп’ютер для подальшого опрацювання. Після передачі зображення ділянки об’єкту контролю на ПК, де за допомогою алгоритмів автоматизованої сегментації зображень отримуються контури виявлених дефектів, об’єкт контролю зсувається на необхідну відстань для отримання знімку наступної ділянки. Цей процес повторюється до тих пір, поки всю поверхню об’єкту контролю не буде проскановано.

2.2. Підбір та опис відеокамер

Промислові камери можна класифікувати залежно від режиму виведення та розділити на дві категорії: аналогові камери та цифрові камери. Оскільки формою вихідного сигналу аналогової камери є стандартний аналоговий відеосигнал, вона повинна бути обладнана спеціальною картою отримання зображення, яка перетворюється на цифрову інформацію, яку можна обробити комп'ютером. Аналогові камери, як правило, використовуються в телевізійних камерах і системах відеоспостереження, мають хорошу універсальність і низьку вартість, але, як правило, нижчу роздільну здатність, повільну швидкість отримання та передачу зображення чутливу до шумових перешкод, що призводить до погіршення якості зображення, тому його можна використовувати тільки для систем машинного зору з низькими вимогами до якості зображення. Навпаки, цифрові камери інтегровані з внутрішньою схемою аналого-цифрового перетворення, який може безпосередньо перетворювати аналоговий сигнал зображення в цифрову інформацію, що не тільки ефективно уникає проблеми перешкод у лінії передачі зображення, але й створює зображення вищої якості. Порівняно з аналоговими камерами, цифрові камери також мають вищу роздільну здатність і частоту кадрів, менший розмір і менші вимоги до енергоспоживання [17]. Таким чином, цифрові камери більше підходять для роботи на швидкісних лініях виробництва сталі та складних середовищах реальних металургійних заводів, ніж аналогові камери.

Якщо розділити промислові камери за типом мікросхеми, то їх можна далі розділити на дві категорії: камери із зарядним зв'язком (ПЗС) і камери на комплементарних металооксидних напівпровідниках (CMOS). Різниця між цими двома камерами полягає в тому, як світло перетворюється на електричні сигнали. Для сенсорів CCD світло, що потрапляє на елемент зображення, створює електричний заряд, який передається та перетворюється на струм, буфер і вихідний сигнал через невелику кількість вихідних електродів. Для сенсорів CMOS кожен елемент зображення завершує власне перетворення

заряду в напругу під час генерації цифрових сигналів. Камери CCD не мають абсолютної переваги перед камерами CMOS, оскільки датчики CCD можуть адаптуватися до діапазону яскравості 0,1–3 люкс, що в 3–10 разів вище, ніж у звичайних камер CMOS, тому сучасні загальні камери CCD мають вищу якість зображення, ніж камери CMOS. Однак, оскільки сенсор CMOS має фоточутливий елемент, підсилювач, аналого-цифровий перетворювач, пам'ять, процесор цифрових сигналів і схему керування комп'ютерним інтерфейсом, вбудовані в кремнієвий чіп, він має просту структуру, швидкий, низьке енергоспоживання, низька вартість та інші характеристики. З розвитком технології низька якість зображення CMOS-камери, малий розмір блоку чутливості зображення та інші проблеми поступово були вирішені завдяки появі «блоку чутливості активного зображення», який збільшив здатність протистояти шуму. Це означає, що датчики CMOS мають майже порівнянну чутливість з датчиками CCD, якість зображення можна покращити, а з точки зору споживання енергії швидкість обробки краща, ніж у датчиків CCD [18]. У світлі фактичного виробничого середовища на металургійних заводах камери CMOS більше підходять для майбутніх систем виявлення дефектів. Датчики CMOS не вимагають складної обробки й безпосередньо перетворюють електрони, що генеруються напівпровідником зображення, у сигнал напруги, тому вони дуже швидкі, перевага, яка робить датчики CMOS дуже корисними для висококадрових камер, де висока швидкість кадру може легко досягати понад тисячі кадрів зі швидкістю, яка дуже підходить для високошвидкісних виробничих ліній.

Підсумовуючи, оскільки процес розпізнавання дефектів сталеві поверхні та отримання зображень набору даних зазвичай виконується на виробничих лініях сталеливарного заводу, а фактичний сталеливарний завод повинен стикатися зі складним і суворим середовищем перевірки вібрацією, світлом, високою температурою, швидкістю, парою і маслом тощо, цифрові камери типу CMOS рекомендуються як справжні інструменти захоплення зображень.

Хорошим варіантом IP-камера Hanwha SNO-L6013RP/AC (рис.2.2).



Рисунок.2.2. Камера Hanwha SNO-L6013RP/AC

Головні характеристики:

- Роздільна здатність: 1920x1080.
- Поле зору: 86,5°.
- Фокусна відстань: 3.6 мм.

Ця камера має достатню роздільну здатність для того, щоб розрізнити дрібні дефекти та достатньо широке поле зору для покриття великої ділянки об'єкту контролю.

2.3. Вибір джерела підсвічування

Оскільки час експозиції камери відносно короткий під час зйомки на високій швидкості, щоб впусити достатньо світла в камеру за короткий час, необхідне належне світло. Відповідна система освітлення може допомогти камері отримати чіткіші зображення, що зробить всю систему перевірки більш ефективною та достовірною. Джерелами світла, які часто використовуються в системі машинного зору, є флуоресцентні лампи, лампи розжарювання, ксенонові лампи та світлодіоди (LED). Серед них світлодіодне джерело світла є найбільш широко використовуваним у сфері розпізнавання дефектів сталі [19, 20, 21]. Це пояснюється тим, що цикл світлодіодного освітлення тривалий, зазвичай може освітлюватися до 100 000 годин, а завдяки меншому нагріванню, низькому енергоспоживанню, рівномірній і стабільній яскравості та різноманітності кольорів можна створювати різноманітні форми та розміри та можна встановлювати різні кути опромінення для задоволення різноманітних

потреб освітлення. Крім того, світлодіодне джерело світла швидко реагує, може досягати максимальної яскравості за 10 мікросекунд або менше, має джерело живлення із зовнішнім тригером, ним можна керувати за допомогою комп'ютера, має швидкий старт, низькі експлуатаційні витрати та довговічність світлодіода, що відобразить більше переваги з точки зору повної вартості та продуктивності. Інструкції щодо налаштування світлодіодного джерела світла можна знайти в [22]. Оскільки деякі сталеві поверхні є відносно гладкими, слід якомога більше уникати дзеркального відбиття, тому до набору світла можна додати розсіювачі, щоб зменшити відблиски, відбиті від металевих зразків.

Найкращим варіантом буде світлодіодна стрічка MTK-600W3528-12 LED/m IP20 Білий Standart (рис.2.3).



Рисунок.2.3. Світлодіодна стрічка MTK-600W3528-12

Світлодіодна стрічка MTK-600W3528-12 має такі характеристики:

- Робоча напруга: 12 В
- Робочий струм: до 0,8 А/метр
- Світловий потік: 800 Лм/метр
- Кут освітлення: 120°
- Кількість світлодіодів: 120 шт/метр

Для управління яскравістю світлодіодів використовуються аналогові виходи ШІМ (PWM – Pulse-Width Modulation). ШІМ є методом управління потужністю, а отже управління яскравістю. Кожні 1/500 секунди ШІМ-вихід виробляє імпульс. Довжина цього імпульсу регулює кількість енергії, яку отримує світлодіод чи двигун. Зовсім немає жодного імпульсу – світлодіод не світиться, короткий імпульс – діод буде світитися тьмяно. Якщо імпульс

активний протягом половини періоду, то світлодіод отримає половину потужності і т. д.

Світлодіоди можуть вмикатися і вимикатися дуже швидко, зазвичай, менше, ніж за мільйонну частку секунди, тому при використанні ШІМ зі світлодіодами, вони насправді блимають з частотою ШІМ, але око бачить ту їх яскравість, яка залежить від частки часу, коли світлодіод справді горить.

2.4. Вибір архітектури нейронної мережі

2.4.1. Fully Convolutional Network

FCN (Fully Convolutional Network) – це архітектура нейронної мережі (рис.2.4) для виконання задач семантичної сегментації зображень [23]. Вона була однією з перших архітектур, яка дозволила виконувати задачу семантичної сегментації зображень з високою достовірністю. У FCN використовуються тільки згорткові та транспоновані згорткові прошарки, що дозволяє працювати з зображеннями різних розмірів та видавати маску, яка вказує на клас кожного пікселя зображення.

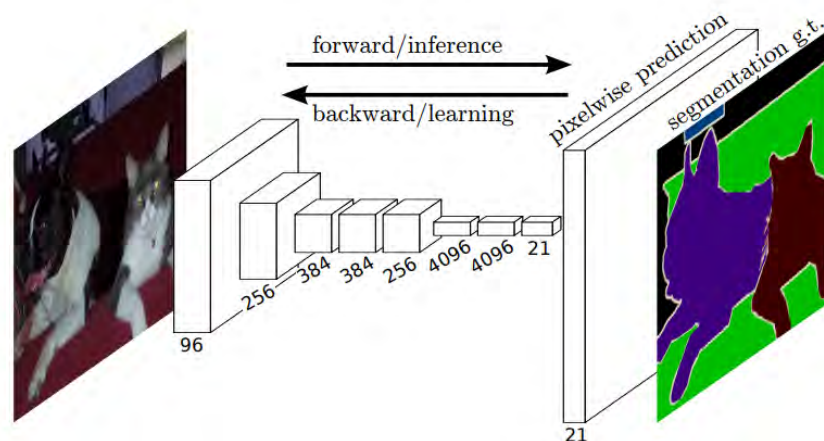


Рисунок.2.4. Архітектура нейронної мережі FCN

Архітектура FCN включає в себе дві головні частини: енкодер та декодер. Енкодер складається з кількох згорткових прошарків, що виконують згортку зображення та зменшення його розміру, зберігаючи при цьому його контекстну інформацію. Декодер складається з транспонованих згорткових прошарків, що

виконують збільшення розміру зображення та відновлюють його роздільну здатність.

Зазвичай FCN використовує декілька каналів маски на кожен клас, який має бути розпізнаний. Після отримання маски можна визначити клас кожного пікселя на зображенні.

Перевагою та одночасно недоліком FCN є кількість параметрів. FCN може бути швидшою в роботі на деяких задачах та займає менше місця на диску, оскільки вона містить менше параметрів та не використовує проміжні з'єднувальні прошарки. Проте може давати менш достовірні результати на зображеннях з високим контрастом та високою роздільною здатністю, може втрачати деяку інформацію при зменшенні розміру зображення. Може мати проблему з відтворенням різних форм об'єктів на зображенні, оскільки вона не використовує з'єднувальні прошарки для зберігання контексту.

2.4.2. DeepLab

Розроблена командою Google у 2016 році та включає в себе декілька важливих інноваційних елементів, таких як атрибутна пулінгова мережа та довгоочікуваний модуль «атрибутних конволюцій» (атрибут – це характеристика зображення, яка описує його окремі властивості).

Архітектура DeepLab [24] використовує підходи з мережами глибокого навчання (рис.2.5), зокрема згорткові та пулінгові прошарки для екстракції різних рівнів властивостей зображення. Однак, вона додатково використовує модуль «атрибутних конволюцій», що дозволяє мережі фокусуватися на областях зображення з високою значимістю.

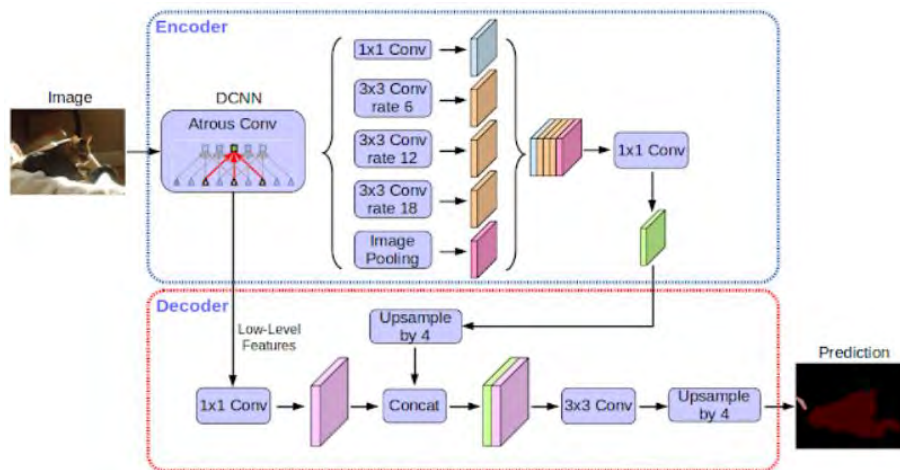


Рисунок.2.5. Архітектура нейронної мережі Deeplab V3+

Основною особливістю архітектури є використання множинних прошарків атрибутної пулінгової мережі (ASPP), що дозволяє мережі аналізувати зображення на різних масштабах. Крім того, вона включає в себе декодер, що використовує вирізання зображень та інтерполяцію для отримання високо якісної сегментації.

Архітектура Deeplab має кілька переваг, зокрема високу достовірність сегментації, здатність працювати з високооб'ємними зображеннями та швидкість обробки, що дозволяє використовувати її для реального часу. Для досягнення цих результатів використовуються декодерні модулі та асиметричні з'єднувальні шляхи, що підвищує ефективність роботи мережі.

Проте, у архітектури Deeplab є й деякі недоліки, серед яких можна відзначити складну структуру та високі вимоги до обчислювальних ресурсів, що робить її менш доступною для застосування на більш простих пристроях. Також, наявність артефактів на межі сегментації може впливати на якість роботи мережі.

2.4.3. LinkNet

Нейронна мережа Linknet [25] є однією з архітектур для сегментації зображень та базується на архітектурі енкодер-декодер (рис.2.6). Linknet була запропонована в 2017 році і розроблена для задач сегментації зображень високої якості з малим розміром датасету.

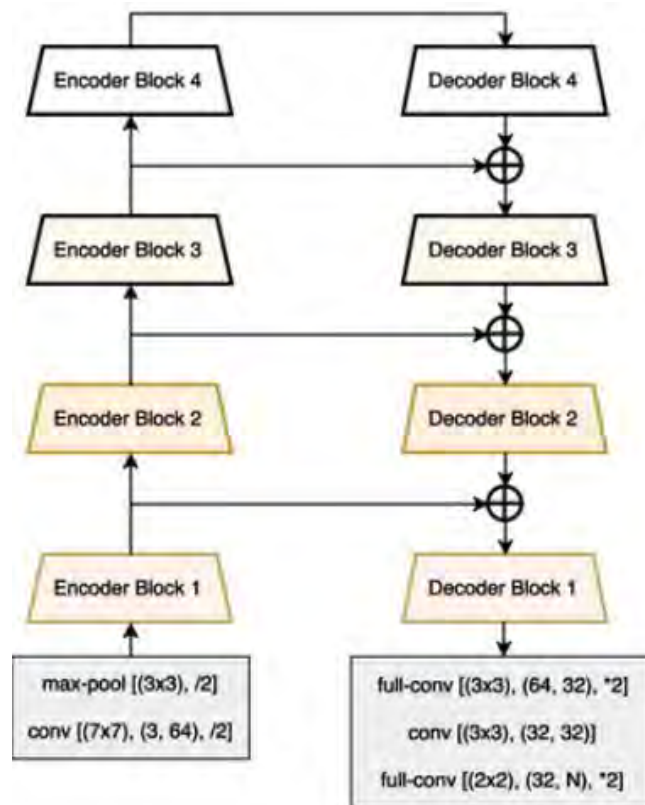


Рисунок.2.6. Архітектура нейронної мережі Linknet

Linknet має енкодер, декодер та механізм зв'язку (linking mechanism), що поєднує вміст між відповідними прошарками енкодера та декодера. Основна ідея полягає в тому, щоб зменшити кількість параметрів, які необхідно навчити, і забезпечити більш ефективну роботу з малими датасетами.

Енкодер у Linknet складається з конволюційних та пулінгових прошарків, які зменшують розмір зображення та розподіляють його на менші сегменти. Потім, у декодері, кожен прошарок розширюється та об'єднується з відповідним прошарком енкодера, щоб збільшити розмір відображення та відновити сегментацію зображення.

У механізмі зв'язку, замість звичайного з'єднання (concatenation) використовується зв'язок у вигляді "shortcut", що передає інформацію з енкодера в декодер без зайвого збільшення кількості параметрів. Це дає змогу збільшити швидкість навчання та зменшити кількість параметрів мережі.

Перевагами архітектури Linknet є швидкість та ефективність, оскільки вона може працювати з великими зображеннями з високою роздільною

здатністю. Крім того, механізм з'єднання дозволяє зберігати важливі деталі при перетворенні зображення, що забезпечує високу достовірність сегментації.

Одним з недоліків архітектури Linknet є її обмежена потужність в порівнянні з іншими сучасними архітектурами. Крім того, її достовірність може знижуватися на зображеннях зі складною структурою та текстурою, де важко визначити межі об'єкту.

2.4.4. U-Net

На сьогоднішній день найкращі результати в завданнях сегментації зображень демонструє нейронна мережа U-Net [26]. Дана мережа має спеціальну згорткову архітектуру, оптимізовану для семантичної сегментації зображень (рис.2.7). Основна її ідея полягає в тому, що мережа має два шляхи проходження даних: звужуючий та розширюючий. Звужуючий шлях відповідає за зменшення розміру зображення та отримання його абстрактних рис – діагностичних ознак. Розширюючий шлях призначений для відновлення оригінального розміру зображення та достовірного відтворення маски сегментації.

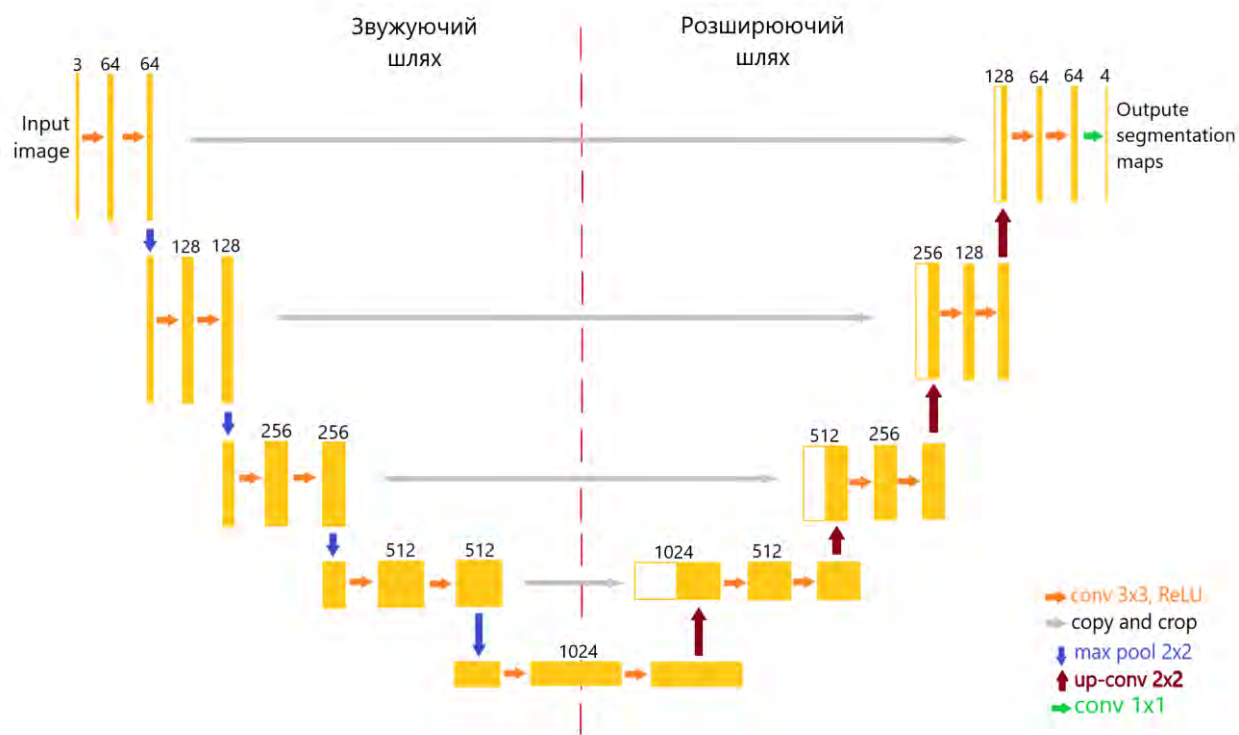


Рисунок.2.7. Базова архітектура нейронної мережі U-Net

Звужуючий шлях складається з кількох послідовних згорткових прошарків з активаційною функцією ReLU, а також прошарки підвибірки з максимальним значенням (max pool). Цей процес зменшує розмір зображення та допомагає відбирати найбільш важливі інформативні ознаки.

Прошарки розширюючого шляху містять оператори зворотної підвибірки (up-sampling), які збільшують розмір карт ознак. Після цього використовуються згорткові прошарки для зменшення кількості каналів ознак. Далі, використовуючи конкатенацію з відповідними картами ознак зі звужуючого шляху, мережа намагається зберегти деталі вхідного зображення та удостоверити маски сегментації.

Останнім прошарком в мережі є згортковий з фільтрами розміру 1x1, який зменшує кількість каналів до кількості класів, що визначає мережа. Наприклад, якщо мережа визначає два класи, то останній згортковий прошарок повертатиме два канали. Кожен канал буде містити маску сегментації для того типу дефекту, який він визначає.

Загалом, U-Net здатна відновлювати зображення з високою достовірністю [27]. У методі U-Net також використовуються зв'язки "skip-connections", які забезпечують передачу інформації між різними прошарками мережі. Це дозволяє більш ефективно використовувати інформацію з різних рівнів роздільної здатності і допомагає уникнути проблеми втрати контексту від дрібних деталей.

Згорткові блоки мережі U-Net організовані у вигляді бекбонів [28]. Бекбон (англ. backbone) – це базова архітектура, яка використовується для побудови складніших мереж. Найчастіше в якості бекбону в мережі U-Net застосовується архітектура ResNet. В такому випадку, архітектура звужуючого шляху мережі U-Net буде ідентичною до архітектури ResNet. А розширюючий шлях являтиме собою обернену копію мережі ResNet. Обчислювальна потужність мережі змінюється в залежності від складності (глибини) бекбону.

2.5. Розробка алгоритмів пост-опрацювання зображення

Розглянемо процес прогнозування контуру дефекту із використанням нейронної мережі. На рисунку 2.8, а наведено приклад анотованого зображення із навчального набору даних, на якому наведено правильні контури дефектів. U-Net на виході для кожного пікселя видає числа в діапазоні в 0 до 1, формуючи маску дефекту. Чим більше значення пікселю, тим вище впевненість мережі у тому, що цей піксель є дефектним. Приклад спрогнозованої маски дефектів на виході мережі наведено на рисунку 2.8, б.

На виході нейронної мережі отримується тривимірний масив кількості каналів якого дорівнює кількості класів дефектів що розпізнаються, а роздільна здатність кожної карти масок дефектів дорівнює роздільній здатності вхідного зображення. У подальшому для отримання контурів дефектів кожного класу відбувається послідовне опрацювання даних з кожного каналу. Для отримання фінального результату сегментації, контури дефектів із кожного каналу накладаються на початкове зображення.

Для отримання контуру дефекту, значення маски необхідно бінаризувати [29] за певним порогом (рис.2.8, в). Бінаризація відбувається за допомогою операції XOR (виключне АБО) перетворюючи числа або бітові рядки на бінарні значення (0 або 1). XOR є логічною операцією, яка повертає 1, якщо вхідні біти відрізняються, і 0, якщо вони однакові.

Процес бінаризації через операцію XOR виглядає так:

1. Починаємо зі значення або бітового рядка, який потрібно бінаризувати.
2. Визначаємо поріг, який буде використовуватися для визначення, коли використовувати значення 0 або 1. Наприклад, якщо ми хочемо бінаризувати числа на основі певного порогу, всі значення, менші або рівні порогу, стають 0, а всі значення, більші за поріг, стають 1.
3. Використовуючи операцію XOR, застосовуємо поріг до вихідного значення або бітового рядка. Кожен біт порівнюється з відповідним

бітом порогу. Якщо біти відрізняються, результат XOR буде 1; якщо біти однакові, результат XOR буде 0.

4. Отримуємо бінарний результат, де 1 позначає, що вихідний біт був вище порогу, а 0 - нижче порогу.

Потім отримана бінарна маска перетворюється в контур певної ширини за допомогою функції `mask2contour` (рис.2.8, г). Розглянемо детальніше кроки, які виконує ця функція:

1. Визначається ширина w і висота h матриці `mask`.
2. Створюється нова матриця `mask2` шляхом з'єднання частини `mask`, що йде після певної ширини `width`, з матрицею з нулями, що має таку ж висоту h , але ширина рівна `width`. З'єднання відбувається вздовж горизонтальної вісі (`axis=1`).
3. Використовуючи операцію XOR, обчислюється елементарне логічне виключне АБО між матрицями `mask` і `mask2`. Отримана матриця зберігається в `mask2`.
4. Створюється ще одна нова матриця `mask3` шляхом з'єднання частини `mask`, що йде після певної висоти `width`, з матрицею з нулями, що має таку ж ширину w , але висота рівна `width`. З'єднання відбувається вздовж вертикальної вісі (`axis=0`).
5. Використовуючи операцію XOR, обчислюється елементарне логічне виключне АБО між матрицею `mask` і `mask3`. Отримана матриця зберігається в `mask3`.
6. Повертається результат логічного ОБО (логічне або) між матрицями `mask2` і `mask3`.
7. Цей контур накладається на початкове зображення (рис.2.8, д).

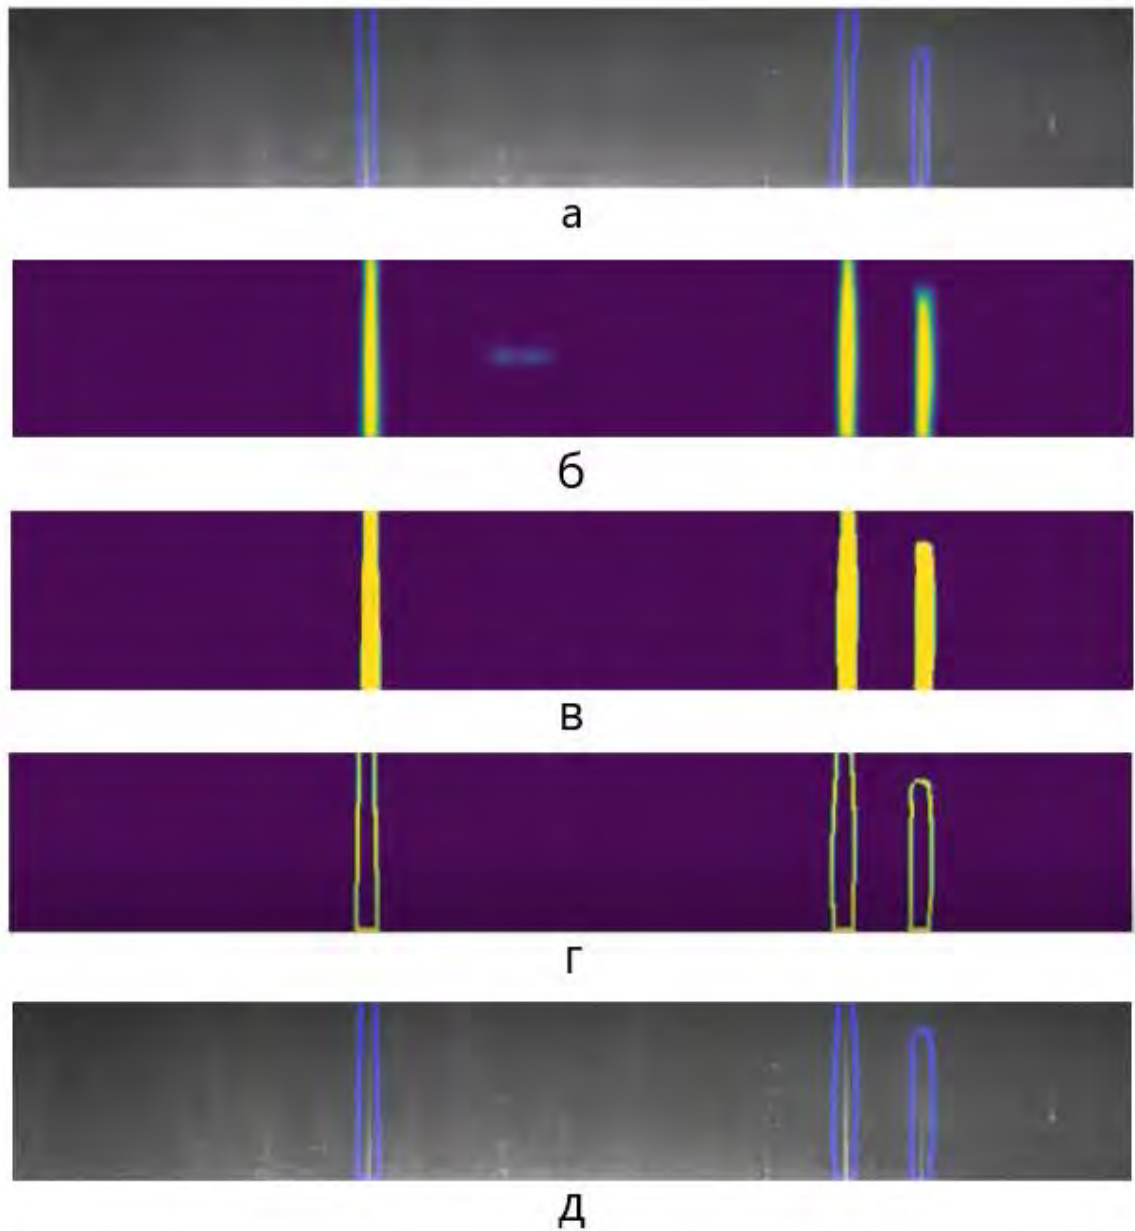


Рисунок.2.8. Процес опрацювання зображення з дефектами: а – правильні контури з навчального набору даних, б – спрогнозована нейронною мережею маска, в – бінаризована спрогнозована маска, г – спрогнозовані нейронною мережею контури, д – спрогнозовані контури, накладені на оригінальне зображення

2.6. Розробка загального алгоритму роботи системи



Рисунок.2.9. Алгоритм роботи системи

Спочатку система вмикає підсвічування поверхні металевого виробу для покращення видимості його дефектів та вмикає камери для збору зображень

поверхні металевого виробу. Відбувається переміщення об'єкта контролю в початкову позицію після чого отримується зображення першої ділянки поверхні металевого виробу. Потім отримане зображення опрацьовується нейронною мережею і починається сегментація можливих поверхневих дефектів. Маска, яка отримана на виході нейронної мережі перетворюється в контур, який показує місце, розмір та форму дефекту. Отримані результати аналізу зберігаються в базі даних та виводяться для їх подальшої обробки. Далі об'єкт контролю переміщується на один крок вперед, щоб отримати зображення іншої ділянки. Процес відбувається до тих пір, поки вся необхідна площа не буде просканована. Останнім етапом є вимкнення підсвітки та камер.

Висновки до розділу

У другому розділі розроблена структурна схема системи. Для отримання зображень було обрано камеру Raspberry Pi High Quality. Для кращої якості зображень треба додаткове джерело світла, для цього використовуватиметься світлодіодна стрічка MTK-600W3528-12 LED/m IP20 Білий Standart.

Після проведення аналізу різних архітектур було вирішено використовувати архітектуру U-Net так як вона проста в реалізації і порівняно з іншими показує високі результати. Тому для початкової версії системи використовувати саме цю архітектуру.

Описано процес прогнозування контуру дефекту з використанням нейронної мережі. U-Net надає маску дефекту на виході, яку потім необхідно бінаризувати та перетворити в контур для подальшого використання. Наведено приклади анованого зображення та спрогнозованої маски дефектів. Розроблено загальний алгоритм роботи системи.

РОЗДІЛ 3. РОЗРОБКА І НАВЧАННЯ НЕЙРОННОЇ МЕРЕЖІ

3.1. Обґрунтування вибору модифікацій U-Net

Є різні модифікації нейронної мережі U-Net, такі як U-Net++, DoubleU-Net, MultiResUNet. Кожна з цих модифікацій має свої особливості та переваги, що можуть бути важливими для розв'язання конкретних задач. Аналізуються різні модифікації з метою вибору найбільш оптимального варіанту для розв'язання поставленої задачі.

3.1.1. U-Net++

UNet++ складається з енкодера та декодера (рис. 3.1, а), які з'єднані через серію вкладених блоків густої згорткової мережі [30]. Основна ідея за UNet++ полягає в тому, щоб зменшити семантичну відстань між карти ознак енкодера та декодера перед злиттям. Наприклад, семантична відстань між $(X^{0,0}, X^{1,3})$ зменшується за допомогою блоку густої згорткової мережі з трьома прошарками згортки. На малюнках чорний колір позначає оригінальну U-Net, зелений та синій кольори показують блоки густої згорткової мережі на шляхах зв'язку, а червоний позначає глибоке керування. Червоні, зелені та сині компоненти розрізняють UNet++ від U-Net. Детальний аналіз першого шляху зв'язку в UNet++ зображено на рис.3.1, б. UNet++ можна обрізати під час виводу, якщо навчати з глибоким керуванням (рис. 3.1, в).

UNet++ можна легко використовувати як архітектуру основи в Mask-RCNN, просто замінивши звичайні зв'язки пропуску на вкладені густі шляхи пропуску.

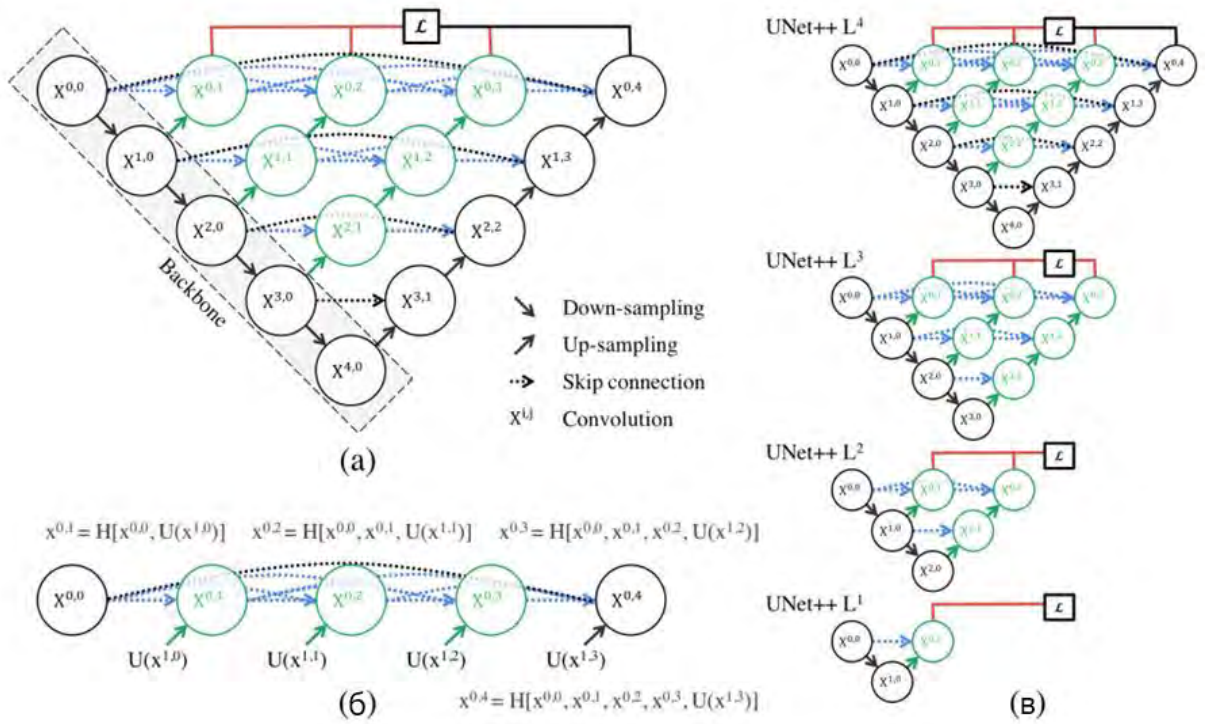


Рисунок.3.1. Архітектура U-Net++: а – енкодер та декодер, б – детальний аналіз першого шляху, в – обрізана частина UNet++

3.1.2. DoubleU-Net

Рисунок 3.2 показує огляд архітектури [31]. Як видно з малюнку, DoubleU-Net починається з VGG-19 як підмережа енкодера, за якою слідує підмережа декодера. Що відрізняє DoubleU-Net від U-Net в першій мережі (NETWORK 1), це використання VGG-19 позначеного жовтим кольором, ASPP позначеного синім, та блоку декодера позначеного світло-зеленим. Блок squeeze-and-excite [32] використовується в енкодері NETWORK 1 та блоках декодера NETWORK 1 та NETWORK 2. Елементне множення виконується між виходом мережі NETWORK 1 та входом тієї ж мережі. Різниця між DoubleU-Net та U-Net у другій мережі (NETWORK 2) полягає лише в використанні ASPP та блоку squeeze-and-excite. Всі інші компоненти залишаються незмінними.

У мережі NETWORK 1 вхідне зображення подається до модифікованої U-Net, яка генерує передбачену маску (Output1). Потім множаться вхідне зображення та згенерована маска (Output1), яка виступає в якості входу до другої модифікованої U-Net, що генерує іншу маску (Output2). Нарешті,

конкатенуються обидві маски (Output1 та Output2), щоб побачити якісну різницю між проміжною маскою (Output1) та кінцевою передбачуваною маскою (Output2).

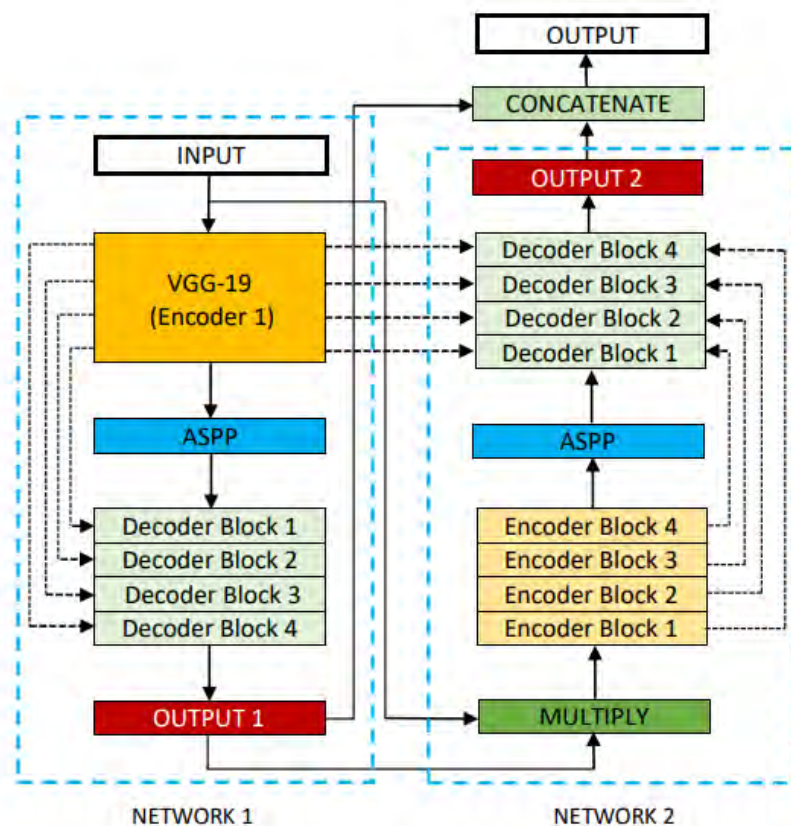


Рисунок.3.2. Блок-схема архітектури DoubleU-Net

3.1.3. MultiResUNet

У моделі MultiResUNet (рис.3.3) замінюється послідовність двох згорткових прошарків на блок MultiRes [33]. Для кожного з блоків MultiRes призначається параметр W , який контролює кількість фільтрів згорткових прошарків всередині цього блоку. Щоб зберегти порівнянне співвідношення між кількістю параметрів в оригінальній U-Net та запропонованій моделі, значення W обчислюється множенням кількості фільтрів U у відповідному прошарку U-Net на коефіцієнт масштабування α . Розкладання W на U та α дає зручний спосіб як контролювати кількість параметрів, так і зберігати їх порівнянними з U-Net. $\alpha = 1,67$, оскільки це дозволяє зберегти кількість параметрів у моделі дещо меншою, ніж у U-Net. Подібно до архітектури U-Net,

після кожної операції об'єднання або деконволюції(зворотної згортки) значення W подвоюється. На додаток до введення блоків MultiRes, замінюються звичайні короткі з'єднання на Residual шляхи. Таким чином, застосовуються деякі операції згортки до карт ознак, що передаються від етапу енкодера до етапу декодера. Також поступово зменшується кількість блоків згортки, що використовуються на Residual шляхах. Зокрема, використовується 4, 3, 2, 1 блок згортки відповідно вздовж чотирьох Residual шляхів. Також, щоб врахувати кількість карт ознак у енкодері-декодері, використовуються 32, 64, 128, 256 фільтрів у блоках чотирьох Residual шляхів відповідно. Всі згорткові прошарки, крім вихідного, що використовуються в цій мережі, активуються функцією активації ReLU (Rectified Linear Unit) [34] та мають нормалізовані батчі. Подібно до моделі U-Net, вихідний прошарок активується сигмоїдальною активаційною функцією.

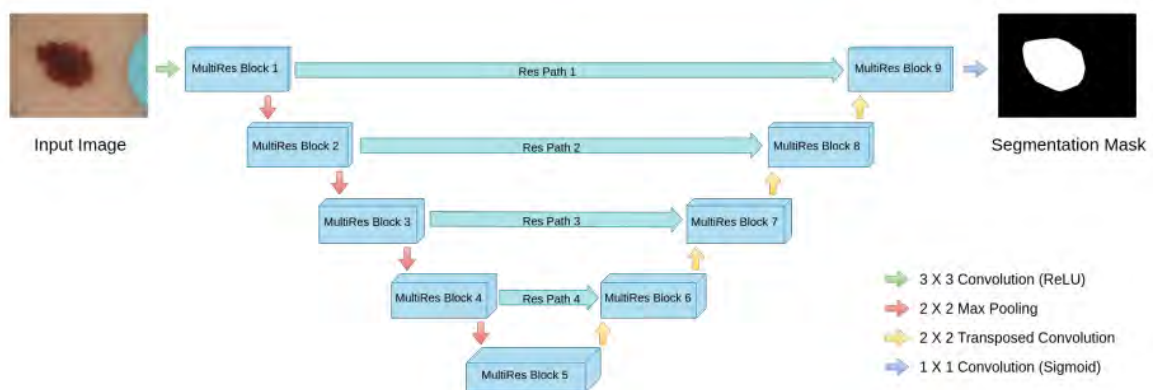


Рисунок.3.3. Архітектура MultiResUNet

3.1.4. Доцільність використання базової моделі U-Net

Усі розглянуті модифікації U-Net є перспективними та потенційно ефективними в різних контекстах. Однак, наразі не існує наукових досліджень, де ця нейронна мережа застосовувалась для детектування поверхневих дефектів металевих виробів. Тому, доцільно провести подальші дослідження використовуючи базову модель з метою визначення її ефективності в задачах дисертації, оскільки саме базова модель може вже забезпечити необхідну достовірність. Однак, у випадку необхідності поліпшення результатів, можна

використовувати розглянуті вище модифікації U-Net для оптимізації роботи системи. Такий підхід дозволить максимально використати можливості базової моделі та потенційно покращити її ефективність, забезпечуючи більш достовірні результати у детектуванні поверхневих дефектів металевих виробів.

3.2. Обґрунтування використання бекбону

Для роботи було обрано базову архітектуру U-Net. Вона була розглянута в класичному вигляді, але для покращення роботи нейронної мережі можна використовувати бекбони. Бекбон (англ. backbone) - це головна частина нейронної мережі, яка отримує вхідні дані і виконує операції, щоб виділити корисну інформацію з цих даних. Наприклад, якщо ми використовуємо нейромережу для розпізнавання обличчя, то бекбон буде витягувати ознаки зображення, такі як форма обличчя, розмір очей і ніздрів, розташування рота і тощо. Отримані ознаки потім передаються до інших частин мережі для подальшої обробки і рішення задачі. Таким чином, бекбон є важливою складовою нейромережі, яка допомагає забезпечити її ефективну та достовірну роботу.

3.2.1. VGG

Архітектура глибокої CNN, названа VGG, з глибиною 16-19 прошарків (рис.3.4) була запропонована Симоньяном і Зіссерманом [35] для задачі класифікації великомасштабних зображень. Розмір фільтрів згортки було зафіксовано на рівні 3×3 для всіх прошарків, щоб забезпечити глибшу реалізацію, одночасно збільшуючи нелінійність функцій (шляхом додавання випрямляючого прошарку після кожної згортки) для вивчення складних зображень. Після прошарків згортки вихідні дані було об'єднано перед з'єднанням з трьома повністю з'єднаними прошарками 4096-D. Це призводить до великої кількості параметрів, які можна навчити: 138 М для прошарків VGG-16 і 144 М для прошарків VGG-19.




Рисунок.3.4. Архітектура нейронної мережі VGG-16

3.2.2. DenseNets

Авторами роботи [36] було запропоновано збудувати глибоку архітектуру, з'єднавши кожен зв'язок згорткового прошарку зі всіма наступними прошарками (рис.3.5), створивши щільно з'єднану мережу, DenseNet. Особливістю є те, що карти ознак з попередніх з'єднаних прошарків перевикористовуються в наступних прошарках, тим самим зменшуючи кількість навчальних параметрів. Крім того, проблема затухаючих градієнтів також вирішується за допомогою залишкових зв'язків між прошарками, які переносять вихід попереднього прошарку до наступного з'єданого прошарку, і дозволяють отримати доступ до градієнтів з кожного прошарку під час зворотнього поширення помилки. DenseNet має значно меншу кількість параметрів порівняно з ResNet такої ж глибини, але все ще зберігає високу ємність для навчання, коли модель стає глибшою.

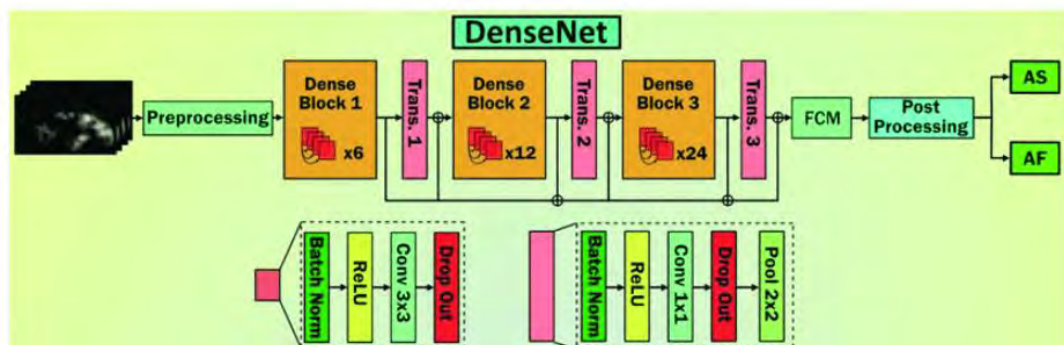


Рисунок.3.5. Архітектура нейронної мережі DenseNet

3.2.3. ResNets

Найчастіше в якості бекбону в мережі U-Net застосовується архітектура ResNet (Рис.3.6). В цій роботі буде використовуватися саме цей бекбон, так як він ефективніший за VGG та DenseNet [37].




Рисунок.3.6. Архітектура мережі ResNet

В такому випадку, архітектура звужуючого шляху мережі U-Net буде ідентичною до архітектури ResNet. А розширюючий шлях являтиме собою обернену копію мережі ResNet. Обчислювальна потужність мережі змінюється в залежності від складності (глибини) бекбону.

При розробці глибших мереж шляхом створення більшої кількості прошарків згорткових нейронів виникає критична проблема під час зворотного поширення, коли градієнти зменшуються і стають занадто малими або зникають, рухаючись до більш нижніх прошарків. Це перешкоджає навчанню та оновленню ваг в цих прошарках, що у свою чергу запобігає збіжності мережі. Тому, додавання додаткових прошарків без жодного виправлення призведе до стагнації достовірності або навіть погіршення продуктивності [38]. Автори статті [38] запропонували рамкову модель з використанням навчання з залишковими зв'язками, що дозволяє краще оптимізувати мережі. Навчання з залишковими зв'язками реалізовано за допомогою "швидкодії" зв'язків, де вихід попереднього прошарку може бути відображений і доданий до виходу

підключених накладених прошарків. Іншою перевагою навчання з залишковими зв'язками є те, що це не призводить до додаткової складності або параметрів мережі, що дозволяє розробляти надзвичайно глибокі мережі (до 152 прошарків) з доволі меншою складністю, ніж у мереж VGG.

3.3. Опис середовища розробки

В даній роботі застосовується бібліотека «segmentation_models», яка використовує як бекенд keras. Keras в свою чергу використовує як бекенд TensorFlow.

TensorFlow створена командою розробників Google Brain, а Keras була розроблена в основному Франсуа Шолле з Google. Гугл використовує TensorFlow в багатьох своїх продуктах та сервісах для розв'язання складних задач машинного навчання. Він має значний вплив на розвиток TensorFlow та Keras, тому ці бібліотеки є найпопулярнішими та рекомендованими виборами для роботи в галузі машинного навчання та глибинного навчання.

3.3.1. TensorFlow

TensorFlow [39] – це наскрізний фреймворк глибокого навчання з відкритим вихідним кодом, розроблений компанією Google і випущений у 2015 році. Він відомий завдяки документації та навчальній підтримці, масштабованим можливостям виробництва та розгортання, декільком рівням абстракції та підтримці різних платформ, таких як Android.

TensorFlow – це бібліотека символічної математики, яка використовується для нейронних мереж і найкраще підходить для програмування потоків даних у широкому спектрі завдань. Вона пропонує кілька рівнів складності для побудови та навчання моделей.

Перспективний і швидкозростаючий вхід у світ глибокого навчання, TensorFlow пропонує гнучку, всеосяжну екосистему ресурсів спільноти, бібліотек та інструментів, які полегшують створення та розгортання додатків для машинного навчання.

3.3.2. Keras

Keras [40] – це ефективний високорівневий інтерфейс прикладного програмування нейронних мереж, написаний на мові Python. Ця бібліотека нейронних мереж з відкритим вихідним кодом призначена для швидкого експериментування з глибокими нейронними мережами [41] і може працювати поверх CNTK, TensorFlow та Theano.

Keras фокусується на модульності, зручності та розширюваності. Він не обробляє низькорівневі обчислення, натомість передає їх іншій бібліотеці, яка називається Backend.

Keras була прийнята та інтегрована в TensorFlow в середині 2017 року. Користувачі можуть отримати доступ до неї через модуль `tf.keras`. Проте, бібліотека Keras все ще може працювати окремо і незалежно.

Порівнюючи Keras та PyTorch, обидва варіанти підійдуть, якщо ви тільки починаєте працювати з фреймворками для глибокого навчання [42]. Математикам і досвідченим дослідникам більше сподобається PyTorch. Keras більше підходить для розробників, яким потрібен фреймворк, що працює за принципом "підключи і працюй", який дозволяє швидко створювати, навчати та оцінювати свої моделі. Keras також пропонує більше варіантів розгортання та простіший експорт моделей.

Обидві платформи користуються достатнім рівнем популярності, тому вони пропонують багато навчальних ресурсів. Keras має чудовий доступ до багаторазового коду та навчальних посібників, тоді як PyTorch має чудову підтримку спільноти та активну розробку.

Keras найкраще підходить для роботи з невеликими наборами даних, швидкого створення прототипів та багатофункціональної підтримки бекенда. Це найпопулярніший фреймворк завдяки своїй порівняльній простоті. Він працює на Linux, MacOS та Windows.

3.3.3. Бібліотека Segmentation models

Segmentation models – бібліотека python з нейронними мережами для сегментації зображень на основі фреймворку Keras (Tensorflow).

Основними особливостями цієї бібліотеки є:

- Високорівневий API (всього два рядки для створення NN)
- 4 моделі архітектур для бінарної та багатокласової сегментації (включаючи легендарну Unet)
- 25 доступних бекбонів для кожної архітектури
- Всі бекбони мають попередньо навчені ваги для швидшої та кращої роботи

Оскільки бібліотека побудована на фреймворку Keras, створена модель сегментації є просто моделлю Keras, яку можна створити так само легко:

```
from segmentation_models import Unet
```

```
model = Unet()
```

Залежно від завдання, можна змінювати архітектуру мережі, вибираючи бекбони з меншою або більшою кількістю параметрів, і використовувати попередньо навчені ваги для її ініціалізації:

```
model = Unet('resnet34', encoder_weights='imagenet')
```

Зміна кількості класів виводу в моделі:

```
model = Unet('resnet34', classes=3, activation='softmax')
```

Зміна розміру вхідних даних моделі:

```
model = Unet('resnet34', input_shape=(None, None, 6), encoder_weights=None)
```

3.4. Опис навчального набору даних

Для навчання нейромережевої моделі використовувався відкритий набір даних від компанії Severstal [43]. Це готовий набір зображень створений за допомогою високочастотних камер для навчання та валідації нейронних мереж. Об'єкт на кожному із зображень може не мати дефектів, мати дефект одного класу або декілька дефектів різних класів. Всього на зображеннях присутні 4

різних класи дефектів, а саме: відколи, одиночна вертикальна тріщина, декілька вертикальних тріщин, одна чи декілька великих плям на поверхні. Маска для кожного класу дефектів закодована в один рядок, навіть якщо на зображенні є декілька неспоріднених дефектних ділянок. Набір даних містить 12568 зображень для навчання та 5506 зображень для тестування. Роздільна здатність зображень складає 800×128 пікселів.

Щоб зменшити розмір файлу анотацій, використовується спеціальний спосіб кодування довжини послідовності значень пікселів. Замість подання вичерпного списку індексів для сегментації, подаються пари значень, які містять початкову позицію та довжину послідовності. Наприклад, '1 3' означає, що починаючи з пікселя 1, треба врахувати 3 пікселі (1,2,3). Таким чином, код '1 3 10 5' означає, що до маски слід включити пікселі 1,2,3,10,11,12,13,14. Алгоритм кодування додатково перевіряє, що числові пари відсортовані, мають додатні значення і розкодовані значення пікселів не дублюються. Нумерація пікселів відбувається зверху вниз, потім зліва направо: піксель 1 – це піксель (1,1), піксель 2 – це піксель (2,1) тощо. На рисунку 3.7 зображено приклад з дефектами третього та четвертого класу, кожен з яких виділений контуром певного кольору.



Рисунок.3.7. Приклад зображення з навчального набору даних

На рисунку 3.8 наведено графік, який відображає розподіл класів дефектів у навчальному наборі даних. Проаналізувавши діаграму робимо висновок, що класи не збалансовані. Більшість (77,3%) зображень містять дефект третього класу і всього 3.7% – дефект другого класу. Незбалансованість класів викликана тим, що під час виробництва деякі дефекти виникають доволі часто. А деякі навпаки, виникають доволі рідко. Тому немає можливості зробити більше знімків зображень, наприклад, дефекту другого класу.




Рисунок.3.8. Розподіл класів дефектів

3.5. Вибір метрик сегментації

Завдання сегментації вимагає використання спеціалізованих метрик, які повинні враховувати як достовірність отриманих масок дефектів, так і якість класифікації. Класична метрика асигуру відображає частку правильно класифікованих пікселів відносно загальної кількості пікселів у наборі даних. Наприклад, якщо модель класифікує 90 зі 100 пікселів правильно, то асигуру буде мати значення 90%. Недоліком є те, що дана метрика погано працює для незбалансованих класів [44].

Більш достовірні оцінки можна отримати за допомогою метрик, заснованих на оцінці помилок першого і другого роду. Так, метрика precision відображає частку правильно класифікованих дефектних пікселів відносно всіх пікселів, які модель віднесла до дефектного класу. Наприклад, якщо модель класифікує 100 пікселів як дефектні, і 80 з них дійсно є дефектними, а 20 визначені хибно, то precision буде дорівнювати 80%.

Recall (чутливість) – це метрика, яка вимірює, яку частку дефектних пікселів було виявлено моделлю по відношенню до загальної кількості пікселів, які дійсно є дефектними. Recall оцінює, наскільки ефективно модель знаходить дефектні пікселі.

Для фінальної оцінки якості класифікації зазвичай використовується F1 Score. Ця метрика дозволяє оцінити збалансованість між precision та recall. F1 Score максимальний, коли precision та recall мають однакове велике значення. Це буде означати, що модель однаково добре виявляє дефектні пікселі та класифікує їх. Даний показник обчислюється за формулою:

$$F1_Score = \frac{2(\textit{precision} \times \textit{recall})}{(\textit{precision} + \textit{recall})} \quad (3.1)$$

У разі використання метрики F1 Score для оцінки якості сегментації формула для розрахунку набуває вигляду:

$$F1_Score = \frac{2 \times |X \cap Y|}{(|X| + |Y|)}, \quad (3.2)$$

де $|X|$ та $|Y|$ – це кількість елементів у вибірці X та Y відповідно, $|X \cap Y|$ – кількість спільних елементів у вибірках X та Y . У нашому випадку X – це анотовані пікселі з навчального набору даних, Y – опрацьовані нейронною мережею пікселі. Подана в такому вигляді метрика F1 Score називається коефіцієнтом Дайса [45]. Коефіцієнт Дайса приймає значення від 0 до 1, де 0 означає повну відсутність спільних елементів, а 1 означає повне співпадіння між вибірками.

Ще однією метрикою для оцінки якості сегментації є IOU (Intersection over Union) або Jaccard index. Вона відображає відношення площі перетину прогнозованої маски та істинної маски до площі їх об'єднання. Інтуїтивно, IOU можна інтерпретувати як міру подібності між прогнозованою та істинною маскою. Це дає змогу оцінити достовірність сегментації моделі для конкретного зображення, а також зробити узагальнену оцінку якості сегментації моделі для всього набору даних.

У практичному застосуванні, часто використовуються модифіковані версії IOU, такі як Mean IOU або IOU Score, які обчислюються для всього набору даних та дозволяють отримати узагальнену оцінку якості сегментації моделі. IOU Score обчислюється як середнє значення IOU по всіх зображеннях в наборі даних. Ця метрика зазвичай використовується в задачах множинної сегментації, коли кожне зображення містить кілька класів об'єктів, що підходить для оцінки якості мережі із архітектурою U-Net.

3.6. Опис параметрів та результатів навчання

На рисунку 3.9 зображено графік навчання моделі із використанням бекбону ResNet18, який ілюструє зміну коефіцієнту Дайса впродовж 30-ти епох. Для навчання були обрані такі налаштування: активаційна функція – 'sigmoid'(перетворює будь-який вхідний сигнал на діапазон значень від 0 до 1), оптимізатор – 'adam' (адаптивний метод оптимізації градієнтного спуску), функція втрат – 'binary_crossentropy' (використовується для визначення, до якого з двох класів належить заданий вхідний елемент).




Рисунок.3.9. Графік зміни коефіцієнту Дайса на навчальній множині

На графіку видно, що перенавчання нейронної мережі немає. В результаті навчання моделі отримано значення коефіцієнту Дайса на рівні 86%, IoU – 75% та Accuracy – 99% на навчальній множині.

Висновки до розділу

Було виявлено, що існують різні модифікації U-Net, які можуть бути використані для сегментації зображень. Однак, для нашої роботи було обрано базову архітектуру U-Net, яка є ефективною для нашої задачі. В якості головної частини нейронної мережі обрано бекбон ResNet, оскільки він є ефективнішим за інші бекбони. Це було обґрунтовано в ході дослідження та аналізу результатів.

Для розробки нашої моделі було використано середовище розробки Keras, оскільки воно є потужним та зручним інструментом для роботи з

нейронними мережами. Описано навчальний набір даних, який містить 12568 зображень для навчання та 5506 зображень для тестування. Для оцінки результатів були вибрані метрики сегментації, а саме IOU Score та коефіцієнт Дайса. Ці метрики дозволяють оцінити якість сегментації та порівняти різні моделі. Описано результати навчання нейронної мережі.

РОЗДІЛ 4. ТЕСТУВАННЯ РОЗРОБЛЕНИХ АЛГОРИТМІВ

4.1. Оцінка результатів роботи системи на тестовій множині

На рисунку 4.1 зображено дефект, обведений синім контуром, який відповідає класу 3. Бачимо, що мережа чітко виділила усі дефекти на металевому листі. Розміри та форма контурів співпадає з тестовими. На зображенні видно білі точки, які б мережа могла помилково виділити як дефекти, проте неіснуючих дефектів виявлено не було.




Рисунок.4.1. Порівняння результату роботи нейронної мережі з тестовим зображенням для дефекту 3

На рисунку 4.2 зображено металевий лист, на якому є одразу два типи дефектів. Дефект, обведений рожевим контуром відповідає класу 4, а дефект обведений синім – 3. Бачимо, що з двома дефектами одразу мережа справляється трохи гірше. Є виділені ділянки, які мережа помилково визначила як дефектні, а одну з дефектних ділянок мережа виділила не повністю. Але ті всі ділянки, на яких є дефекти, вона знайшла і правильно класифікувала, що є доволі хорошим результатом.




Рисунок.4.2. Порівняння результату роботи нейронної мережі з тестовим зображенням для дефектів 3 та 4 одночасно

Модель із використанням бекбону Resnet18 показує такі результати: коефіцієнт Дайса – 69% та IOUScore – 53%.

4.2. Аналіз ефективності використання різних бекбонів

Під час навчання проводилось тестування п'яти різних варіантів бекбонів архітектури ResNet. Усереднені результати роботи мережі із використанням кожного з використаних бекбонів містяться у таблиці 4.1. На перший погляд, параметр асигасу, показує неймовірно гарні результати. Але під час обчислення даного параметру враховується клас фону, який займає більшу частину зображення. Це призводить до критичної незбалансованості класів, що робить метрику асигасу недостовірною для даних умов [46].

Найкращі результати показує модель із використанням бекбону Resnet18, яка має коефіцієнт Дайса – 69% та IOUScore – 53%. Водночас, ця модель має найменшу кількість параметрів. Тобто, знадобиться набагато менше часу для її навчання, у порівнянні з більш складними бекбонами. Найгірші показники були отримані для бекбону ResNet152, хоча така мережа має найбільшу кількість параметрів.

Таблиця 4.1. Порівняння результатів роботи різних бекбонів

Бекбони	Параметри	Асс	Dice	IOUScore
Resnet18	11М	0.992	0.691	0.531
Resnet34	21М	0.992	0.672	0.509
Resnet50	23М	0.992	0.672	0.509
Resnet101	42М	0.992	0.674	0.511
Resnet152	58М	0.992	0.666	0.502

З таблиці 4.1 видно, що досить помітні зміни у кількості параметрів мають незначний вплив на якість моделі. Таким чином, можна зробити висновок, що збільшення кількості параметрів моделі не завжди призводить до покращення її ефективності. Окрім того, з таблиці видно, що всі розглянуті моделі мають значення Dice коефіцієнту на рівні до 69%. Це означає, що отримані маски сегментації є достовірними. Про достовірність сегментації свідчить і порівняно високе значення показника IOUScore [47].

4.3. Аналіз впливу порогового рівня на розмір маски

Для дослідження залежності коректності прогнозування контурів від порогу бінаризації було розглянуто 5 значень порогів: 0.1, 0.25, 0.5, 0.75, 0.9. Щоб визначити оптимальний поріг для сегментації зображень, потрібно врахувати два фактори: кількість правильних масок і кількість неправильних масок, отриманих за даного значення порогу. В ідеалі, необхідно вибрати поріг, який максимізує кількість правильних масок і мінімізує кількість неправильних масок.

В таблиці 4.2 наведено кількість правильно і неправильно спрогнозованих масок для кожного дефекту за різних значень порогу бінаризації. Видно, що зі збільшенням порогового рівня кількість неправильних масок загалом зменшується, тоді як кількість правильних масок залишається відносно стабільною або незначно зменшується.

Таблиця 4.2. Розміри масок з різними порогоми

Поріг	Дефект 1		Дефект 2		Дефект 3		Дефект 4	
	Правильні маски	Неправильні маски	Правильні маски	Неправильні маски	Правильні маски	Неправильні маски	Правильні маски	Неправильні маски
0.1	25	157	4	65	864	280	22	176
0.25	24	136	4	60	837	270	19	157
0.5	20	116	2	45	815	260	19	144
0.75	18	97	1	26	786	256	17	137
0.9	13	67	1	10	746	237	17	130

Однак існує точка, коли подальше збільшення порогу не призводить до значного зменшення кількості хибних спрацьовувань, але призводить до

помітного зменшення кількості вірних спрацювань. Наприклад, для дефекту 1 кількість правильних масок падає з 25 за порогу 0.1 до 13 за порогу 0.9. Тоді як кількість неправильних масок падає з 157 до 67. Це свідчить про те, що поріг близько 0.5 або 0.75 буде найбільш збалансованим за показником правильних і неправильних спрацювань для цього дефекту. Аналогічно для дефекту 2.

Для дефектів 3 і 4 ми бачимо більшу кількість правильних масок, але спостерігаємо ту саму загальну тенденцію до зменшення кількості хибних і правильних масок зі збільшенням порогу. В обох випадках поріг близько 0.75 буде найбільш збалансованим. На рисунку 4.3 можна побачити гістограми залежності розміру спрогнозованого мережею контуру (у пікселях) від порогового рівня для дефекту №3.

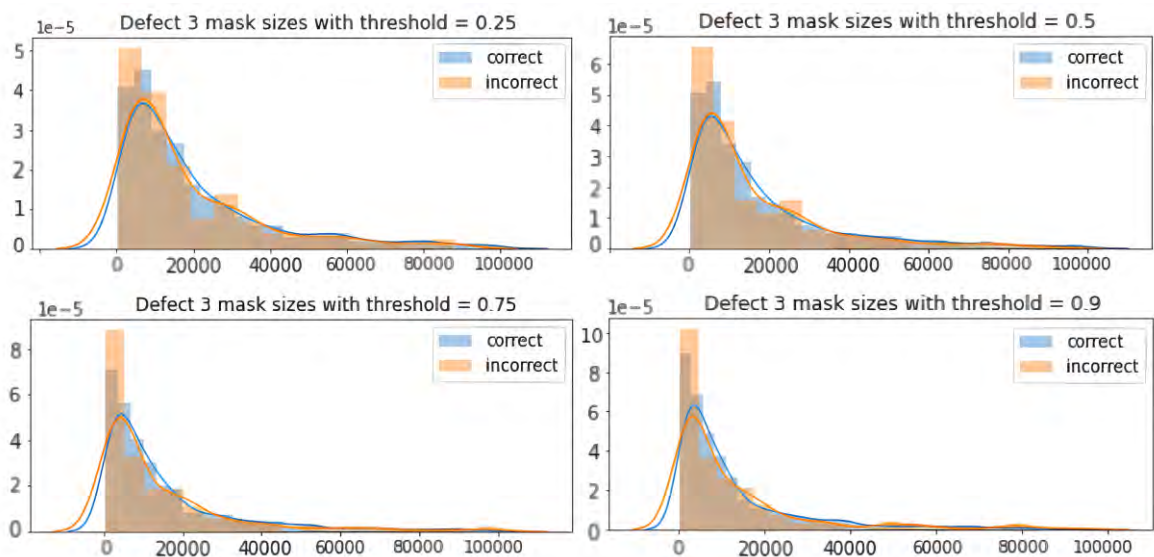


Рисунок.4.3. Гістограми розподілу розмірів правильних та хибних масок дефектів

Отже, оптимальний пороговий рівень бінаризації масок для мережі U-Net залежить від конкретного випадку і може бути встановлений емпіричним шляхом. Для досягнення найкращих результатів сегментації зображень поверхневих дефектів сталі мережею U-Net, навченої на використаному у дослідженні наборі даних, оптимальним є значення порогу бінаризації на рівні 0,5...0,75. Для інших наборів навчальних даних або архітектур мереж для сегментації це значення може відрізнятись та має обиратись з огляду на найкращий баланс між кількістю коректних та хибних масок.

4.4. Перспективні шляхи вдосконалення системи

Використання моделей глибокого навчання має ряд переваг у порівнянні з класичними методами сегментації, однак є і обмеження. З існуючих обмежень можна виділити те, що для навчання нейронної мережі потрібно мати велику кількість анотованих зображень дефектів металевих поверхонь. Недостатня кількість зображень або їх низька репрезентативність призводить до погіршення якості сегментації, що є загальним недоліком для всіх моделей глибокого навчання. Використання нейронної мережі U-Net може мати обмеження у якості сегментації, якщо дефекти на поверхні металу складніші за ті, на яких навчалась мережа.

Одним з можливих напрямів подальших досліджень є вдосконалення архітектури нейронної мережі для покращення значень отриманих метрик. Наприклад на основі розглянутих в роботі архітектур можна запропонувати використання U-Net++, DoubleU-Net, MultiResUNet. Також викликає інтерес дослідження можливості використання інших типів нейронних мереж або їх гібридних моделей. Іншим важливим завданням є розширення набору навчальних даних. Зокрема, збільшення роздільної здатності зображень, збільшення кількості класів дефектів та якості їх анотацій.

Завдяки високій адаптивності даного методу, у майбутньому можна розглянути можливість його використання для інших цілей. Наприклад, для автоматизованої сегментації дефектів на інших типах поверхонь. Використання нейронних мереж в автоматизованій сегментації зображень має великий потенціал для застосування в багатьох сферах, включаючи медицину [48], промисловість, транспорт та багато інших.

Висновки до розділу

У цьому розділі оцінено результати роботи системи на тестовій множині. Проаналізовано ефективність використання п'яти різних варіантів бекбонів архітектури ResNet. Виявлено, що найкращі результати показує модель із

використанням бекбону Resnet18, яка має коефіцієнт Дайса – 69% та IOUScore – 53%. Водночас, ця модель має найменшу кількість параметрів. Тобто, знадобиться набагато менше часу для її навчання, у порівнянні з більш складними бекбонами. Найгірші показники були отримані для бекбону ResNet152, хоча така мережа має найбільшу кількість параметрів. Проаналізовано вплив порогового рівня на розмір маски. Для досягнення найкращих результатів сегментації зображень поверхневих дефектів стали мережею U-Net, навченої на використаному у дослідженні наборі даних, оптимальним є значення порогу бінаризації на рівні 0,5...0,75. Описані недоліки та перспективні шляхи вдосконалення системи.

РОЗДІЛ 5. РОЗРОБКА СТАРТАП-ПРОЕКТУ «УДОСКОНАЛЕНІ АЛГОРИТМИ СЕГМЕНТАЦІЇ ЗОБРАЖЕНЬ ПОВЕРХНЕВИХ ДЕФЕКТІВ МЕТАЛЕВИХ ВИРОБІВ»

В цьому розділі буде проведено маркетинговий аналіз проекту магістерської дисертації для визначення можливості його ринкового впровадження. Для аналізу використаний алгоритм наведений в [49].

5.1. Опис та технологічний аудит ідеї проекту

У цьому підрозділі ми зосередимось на детальному описі ідеї нашого стартапу та проведемо технологічний аудит, щоб визначити його потенційні можливості та недоліки. Ми розглянемо ключові технологічні аспекти, що стоять за нашим продуктом, визначимо технічні вимоги та обмеження, а також проаналізуємо конкурентні переваги нашої ідеї на ринку. Після проведення технологічного аудиту ми зможемо зрозуміти, наскільки наша ідея є життєздатною та які кроки потрібно зробити, щоб максимально використати її потенціал та здобути успіх на ринку. Можливі напрямки використання, зміст ідеї та вигоди для користувача наведені в таблиці 5.1.

Таблиця 5.1. Опис ідеї стартап-проекту [49]

Зміст ідеї	Напрямки застосування	Вигоди для користувача
Удосконалення методу визначення дефектів металевих виробів за результатами візуально-оптичного контролю з використанням нейронних мереж.	Визначення дефектів у багат шарових матеріалах	Автоматизована система забезпечує високу ефективність та швидкість визначення дефектів та їх класифікацію на металевих поверхнях

В таблиці 5.1 наведено головний напрямок використання автоматизованої системи, основними користувачами є компанії, які займаються виробництвом

металевих виробів.

Інформаційна карта стартап проекту наведена в таблиці 5.2, вона включає в себе назву та авторів проекту, термін реалізації, необхідні ресурси, описує проблематику та основні цілі.

Таблиця 5.2. Інформаційна картка стартап-проекту [50]

Назва проекту	DefectDetect
Автори	Стешенко Я.В., Протасов А.Г.
Анотація	DefectDetect – це стартап, який розробляє інноваційний алгоритм сегментації зображень поверхневих дефектів металевих виробів. Цей алгоритм забезпечує більш достовірну та швидку ідентифікацію дефектів, таких як тріщини, вимивання та корозія на металевих поверхнях.
Термін реалізації	1 рік
Необхідні ресурси	Людські, фінансові.
Опис проблеми, яку вирішує стартап - проект	Зараз на ринку існують різні методи детекції поверхневих дефектів, але вони не завжди є достовірними та ефективними. Часто методи, які застосовуються в промисловості, потребують великої кількості ручної роботи та часу, що затримує процес виробництва та збільшує витрати на контроль якості.
Ціль	Метою DefectDetect є за допомогою навчання нейронних мереж збільшити швидкість обробки зображень, виявлення дефектів їх класифікація.
Очікуваний результат	Навчання нейронної мережі для швидкої обробки зображень.

За допомогою застосування морфологічних карт слід згенерувати ідею алгоритму сегментації зображень поверхневих дефектів металевих виробів, яка

б забезпечувала підвищену інформативність та достовірність роботи, ніж існуючі, була б зручною у використанні.

Ідея проєкту генерується відповідно до такого алгоритму (табл. 5.3):

- визначити функції, які повинен виконувати проєкт;
- подання на карті декількох варіантів елементарних рішень, тобто засобів за допомогою яких можна реалізувати кожну функцію;
- вибір по одному елементарному рішенню для кожної функції.

Таблиця 5.3. Морфологічна карта [50]

Функції	Проміжні рішення				
	1-ше	2-ге	3-тє	4-тє	5-тє
Методи сегментації зображень	Методи основані на сегментації за допомогою навчання без вчителя	Методи основані на сегментації за допомогою навчання з вчителем	Методи основані на формі та контурі	Методи основані на кольорі	Методи порогової обробки
Нейронні мережі для виявлення дефектів на металевих поверхнях	Автоенкодеру (Autoencoders)	U-Net	Контурові моделі (Active Contour Models)	Конволюційна нейронна мережа (Convolutional Neural Network, CNN)	Інше

Отже ідею стартап-проєкту можна сформулювати так: удосконалення

алгоритмів сегментації зображень поверхневих дефектів металевих виробів із застосуванням нейромережових технологій [51], що забезпечуватиме підвищення ефективності та якості продукції.

Визначимо попереднє коло конкурентів, товарів-аналогів або товарів-замінників, що вже впроваджені на ринок. Дослідимо техніко-економічні властивості та характеристики ідеї. Проведемо порівняльний аналіз показників (табл.5.4).

Таблиця 5.4. Визначення сильних, слабких та нейтральних характеристик ідеї проєкту [49]

№ п/ п	Техніко- економічні характеристик и ідеї	(потенційні) товари/концепції конкурентів			W (слабка сторона)	N (нейтра- льна сторона)	S (сильна сторона)
		Мій проєкт	Cognex	Omron			
1.	Коефіцієнт Дайса, %	69	67	64			+
2.	Помилка класифікації дефектів, %	31	33	36			+
3.	Кількість виявлених об'єктів (з 100)	100	99	98		+	
4.	Надійність	Висока	Висока	Висока		+	
5.	Ціна	Низька	Висока	Середня			+

З таблиці 5.4 можемо зробити висновок, що порівняно із головними

конкурентами, перевагою проекту є результати коефіцієнту Дайса, відсоток помилки класифікації дефектних зображень та низька ціна. Ці переваги є підґрунтям для формування його конкурентоспроможності.

Далі необхідно дослідити аудит технології, за допомогою якої можна реалізувати ідею проекту, для цього визначаємо всі ідеї проекту, за якими технологіями вони будуть реалізовуватись, чи наявні та доступні ці технології (табл. 5.5) [49].

Таблиця 5.5. Технологічна здійсненність ідеї проекту [49]

<i>Ідея проекту</i>	<i>Технології її реалізації</i>	<i>Наявність технологій</i>	<i>Доступність технологій</i>
Виявлення дефектів на металевих поверхнях	Розробка нейронної мережі в середовищі Kaggle	Наявні	Технологія доступна
Визначення характеристик об'єктів	Розробка нейронної мережі в середовищі Kaggle	Наявні	Технологія доступна

Методика реалізації ідеї проекту базується на розробці нейронних мереж для розпізнавання та визначення характеристик об'єктів. При цьому це не потребує вагомих ресурсів і дає змогу проводити дослідження у широкому спектрі вхідних даних. За даними наведеними в таблиці 5.5 можемо зробити висновок, що всі ідеї проекту можна технологічно реалізувати оскільки технології наявні на ринку та доступна для авторів.

5.2. Аналіз ринкових можливостей запуску стартап-проекту

В цьому підрозділі досліджується можливості та загрози під час виходу на ринок, стан ринкового середовища і потреби цільової аудиторії.

Проведемо попередній аналіз на наявність попиту та динаміку розвитку

ринку (табл. 5.6).

Таблиця 5.6. Попередня характеристика потенційного ринку стартап-проєкту [49]

№ п/п	Показники стану ринку (найменування)	Характеристика
1	Кількість головних гравців, од	3
2	Загальний обсяг продаж, грн	8000000
3	Динаміка ринку (якісна оцінка)	Зростає
4	Наявність обмежень для входу (вказати характер обмежень)	Конкуренція існуючих компаній
5	Специфічні вимоги до стандартизації та сертифікації	Загальні технічні умови
6	Середня норма рентабельності в галузі (або по ринку), %	32%

За попереднім оцінюванням та даними занесеними до таблиці 5 робимо висновок, що ринок є привабливим для входження, оскільки динаміка ринку зростає.

Далі визначимо потенційні групи клієнтів, сформуємо вимоги до товару для кожної цільової групи (табл.5.7). Кожен товар має свого потенційного клієнта. Він є представником цільової аудиторії компанії, якими є люди певної статі, віку, зі схожими потребами, інтересами та фінансовими можливостями.

Параметри, які описують потенційного покупця:

- є потреба та бажання придбати товар;
- є фінансова можливість придбання;
- має право приймати рішення щодо покупки.

Таблиця 5.7. Характеристика потенційних клієнтів стартап-проєкту [49]

<i>Потреба, що формує ринок</i>	<i>Цільова аудиторія (цільові сегменти ринку)</i>	<i>Відмінності у поведінці різних потенційних цільових груп клієнтів</i>	<i>Вимоги споживачів до товару</i>
Удосконалення алгоритмів сегментації зображень поверхневих дефектів металевих виробів	Виробництва металевих виробів, контроль якості та інші	Особливості, викликані зі специфікою проведення дослідів	Висока достовірність, швидкість обробки, гнучкість і адаптабельність, інтеграція та сумісність

Портрет цільової аудиторії – це сукупність різних характеристик потенційних клієнтів. Для того, щоб скласти якісний портрет необхідно більш детально визначити параметри кожної групи споживачів. Дані занесено до таблиці 5.8.

Таблиця 5.8. Портрет цільового покупця

Що хочуть купити	Комп'ютерну програму
Хто покупець	Підприємства, що виготовляють металеві вироби та компанії, що спеціалізуються на контролі якості металевих виробів
Мета купівлі	Покращення якості продукції, зниження витрат на контроль якості, збільшення ефективності процесів

Продовження таблиці 5.8

Коли покупець купує продукт	Коли з'являється необхідність у більш достовірному та дешевшому контролі якості металевих поверхонь
Де покупець бажає придбати продукт	Онлайн
Мета стартапера	Задовольнити потребу клієнта в більш якісному продукті.

З таблиці 5.8 робимо висновок, що основними клієнтами для нас є підприємства, що виготовляють металеві вироби та компанії, що спеціалізуються на контролі якості металевих виробів у яких є потреба у більш достовірному та дешевшому контролі якості металевих поверхонь.

Визначимо можливості та загрози, які можуть виникнути під час входження на ринок (табл. 5.9, 5.10).

Ринкові можливості – це сприятливі обставини, які підприємство може використовувати для отримання переваг. Як приклад ринкових можливостей можна привести погіршення позицій конкурентів, різке зростання попиту, появу нових технологій виробництва продукції, зростання рівня доходів населення і т. п. Слід зазначити, що можливостями з погляду SWOT-аналізу є не всі можливості, які існують на ринку, а тільки ті, які можна використовувати.

Ринкові загрози – події, настання яких може несприятливо вплинути на підприємство. Приклади ринкових загроз: вихід на ринок нових конкурентів, зростання податків, зміна смаків покупців, зниження народжуваності й т. п.

Таблиця 5.9. Фактори загроз [49]

<i>№ п/п</i>	<i>Фактор</i>	<i>Зміст загрози</i>	<i>Можлива реакція компанії</i>
1	Зріст конкуренції	Конкуренти мають нижчі ціни	Покращення конкурентоспроможності продукту
2	Відсутність попиту	У клієнтів немає потреби в покупці товару	Визначення потреб клієнтів
3	Зміни в стандартизації	Зміни в ДСТУ	Модернізація системи відповідно до нових стандартів
4	Вартість досліджень	Висока вартість проведення нових досліджень	Додаткові витрати на проведення дослідження
5	Якість	Не задоволення очікувань клієнтів	Покращення конкурентоспроможності продукту

Основними загрозами є зріст конкуренції та відсутність попиту, адже для проведення нових досліджень необхідні додаткові витрати, щоб уникнути таких наслідків потрібно покращити маркетинг, для того щоб більше потенційних клієнтів дізнались про переваги проекту.

Таблиця 5.10. Фактори можливостей [49]

<i>№ n/n</i>	<i>Фактор</i>	<i>Зміст можливості</i>	<i>Можлива реакція компанії</i>
1	Збільшення попиту	Збільшення зацікавлення клієнтів дослідженнями	Можливість отримання інвестицій
2	Обслуговування	Потреба в обслуговуванні	Повірка та встановлення обладнання
3	Освоєння нових сфер	Використання системи в нових сферах, що не розглядалися раніше	Модернізація системи для покращення її основних параметрів та виконання поставлених вимог
4	Впровадження нових технологій	Якісне покращення основних параметрів продукту та модернізація раніше існуючих рішень	Підвищення попиту та ціни
5	Інвестиції	Залучення нових інвестицій	Збільшення витрат на дослідження та маркетинг

Фактор збільшення попиту є найбільш реальним, оскільки система задовольняє вимоги потенційних клієнтів, а саме має високу достовірність та швидкість. Інвестиції в значній мірі допомагають вивести бізнес на новий рівень, тому важливо залучати до співпраці нових інвесторів.

Після аналізу загроз та можливостей можемо зробити висновок, що ринок автоматизованих систем аналізу даних тепловізійного відеонагляду є перспективним для входу нових компаній.

Далі проведемо аналіз пропозиції та визначимо основні риси конкуренції на

ринку (табл. 5.11).

Конкуренція – це суперництво між суб'єктами ринкової економіки за найкращі умови виробництва, вигідну позицію на ринку тощо.

Конкуренти – це компанії, які працюють на тому ж ринку, з тієї ж цільовою аудиторією і надають аналогічний продукт або послугу.

Таблиця 5.11. Ступеневий аналіз конкуренції на ринку [49]

<i>№ n/n</i>	<i>Особливості конкурентного середовища</i>	<i>В чому проявляється дана характеристика</i>	<i>Вплив на діяльність підприємства (можливі дії компанії, щоб бути конкурентоспроможною)</i>
1	Чиста конкуренція	Окремі компанії не можуть вплинути на ціну	Концентрації діяльності підприємства на якість товару
2	За рівнем конкурентної боротьби – міжнародний	Наявність клієнтів із інших держав	Вихід на міжнародний ринок
3	Конкуренція за галузевою ознакою – внутрішньогалузева	Використовується в одній галузі	Покращення реклами та залучення нових клієнтів
4	Конкуренція за видами товарів – товарно-видова	Конкуренція, що виникає між товарами одного виду	Клієнтоорієнтовність та адаптивність до вимог ринку

Продовження таблиці 5.11

<i>№ n/n</i>	<i>Особливості конкурентного середовища</i>	<i>В чому проявляється дана характеристика</i>	<i>Вплив на діяльність підприємства (можливі дії компанії, щоб бути конкурентоспроможною)</i>
5	За характером конкурентних переваг – нецінова	Ціна залежить від функціоналу та методу дослідження	Пошук можливостей збільшення якості товару
6	За інтенсивністю – марочна	Конкурентні компанії пропонують подібні продукти	Покращувати якість товару, знижувати ціну. Створення фірмового стилю компанії та реклама.

Проаналізувавши таблицю 5.11 робимо висновок, що через малу кількість конкурентів на ринку спостерігається чиста конкуренція. Всі конкуренти мають різні методики досліджень. Конкурентна боротьба є міжнародною та внутрішньогалузевою.

Далі проводиться більш детальний аналіз конкуренції в даній галузі за моделлю М. Портера (табл. 5.12) та обґрунтування факторів конкурентоспроможності (табл. 5.13).

М. Портер вирізняє п'ять основних факторів, що впливають на привабливість вибору ринку з огляду на характер конкуренції:

- конкурент, що вже є у галузі;
- потенційні конкуренти;
- наявність товарів-замінників;
- постачальники, що конкурують за ринкову владу;
- споживачі.

Таблиця 5.12. Аналіз конкуренції в галузі за М. Портером [49]

Складові аналізу	Прямі конкуренти в галузі	Потенційні конкуренти	Постачальники	Товари-замінники
		Omron	Невисокий бар'єр входження на в ринок	Наявність ліцензії на програмне забезпечення
Висновки:	Невелика конкуренція	Є можливості виходу на ринок. Є великі конкуренти. Строк виходу на ринок 1 рік	Умови роботи на ринку постачальники не диктують	Обмежень для роботи практично немає, оскільки товари-замінники використовують інші методи діагностики

Таблиця 5.13. Обґрунтування факторів конкурентоспроможності [49]

№ п/п	Фактор конкурентоспроможності	Обґрунтування (наведення чинників, що роблять фактор для порівняння конкурентних проєктів значущим)
1	Ціна	Оптимальна ціна при високій якості
2	Достовірність	Необхідна найменш можлива похибка діагностики
3	Інформативність	Висока інформативність
4	Якість	Висока якість

Після оцінки конкуренції та основних факторів конкурентоспроможності,

дані про які наведені в таблицях 5.12-5.13, можна сказати, що всі вищезгадані фактори досягаються проведенням додаткових досліджень та розрахунків. За цими факторами будуємо таблицю слабких та сильних сторін стартап-проєкту (табл. 5.14).

Таблиця 5.14. Порівняльний аналіз сильних та слабких сторін [49]

№ п/ п	Фактор конкурентоспроможності	Бали 1-20	Рейтинг товарів-конкурентів у порівнянні з CPDK						
			-3	-2	-1	0	+1	+2	+3
1	Ціна	15				0			
2	Достовірність	20						2	
3	Інформативність	19							3
4	Якість	19					1		

Проаналізувавши таблицю 5.14 робимо висновок, що стартап-проєкт в підсумку має вищий рейтинг ніж його прямий конкурент. Дана таблиця показує переваги проєкту над конкурентами.

На основі виділених раніше сильних та слабких сторін, а також ринкових можливостей та загроз, складемо таблицю SWOT- аналізу (табл. 5.15).

Таблиця 5.15. SWOT- аналіз стартап-проєкту [49]

<p>Сильні сторони:</p> <ol style="list-style-type: none"> 1. Ширший діапазон визначення дефектів 2. Висока достовірність 3. Зростання попиту 4. Обслуговування 5. Модифікація 	<p>Слабкі сторони:</p> <ol style="list-style-type: none"> 1. Поява нових технологій 2. Збільшення конкуренції на ринку 3. Початківець на ринку
<p>Можливості:</p> <ol style="list-style-type: none"> 1. Збільшення кількості клієнтів 2. Закріпитись на ринку 3. Збільшення обсягу продажів 4. Можливість проведення перевірок 5. Покращення характеристик приладу 	<p>Загрози:</p> <ol style="list-style-type: none"> 1. Кращі умови та якість від конкурентів 2. Відсутність клієнтів 3. Зниження доходів потенційних споживачів.

Потрібно звернути увагу на можливість появи загроз, таких як відсутність клієнтів та покращення якості продукції конкурентів. Необхідно утримати клієнтів за рахунок надання безкоштовних додаткових модифікацій. На основі SWOT-аналізу описаного в таблиці 5.15 розробляємо альтернативи для виходу стартап-проєкту на ринок та орієнтовні терміни для їх реалізації (табл. 5.16).

Таблиця 2.16 Альтернативи ринкового впровадження стартап-проєкту [49]

<i>№ n/n</i>	<i>Альтернатива (орієнтовний комплекс заходів) ринкової поведінки</i>	<i>Ймовірність отримання ресурсів</i>	<i>Строки реалізації</i>
1	Покращення розпізнавання дефектів	Середня	6 місяців
2	Покращення надійності	Висока	6 місяців

Проаналізувавши дані наведені в таблиці 5.16 робимо висновок, що найкращою альтернативою є збільшення надійності приладу оскільки така альтернатива має високу ймовірність отримання додаткових ресурсів.

Далі опрацюємо питання для удосконалення продукту (табл. 5.17).

Таблиця 5.17. Опрацювання питань для удосконалення продукту

<i>№ n/n</i>	<i>Запитання</i>	<i>Відповідь</i>
1	Частиною яких систем є продукт?	Систем візуально-оптичного неруйнівного контролю
2	Чи можна розділити продукт на частини?	Так, можна окремо використовувати програмне забезпечення без відеокамер, що передають автоматично дані.
3	Чи можна об'єднати (агрегувати) кілька елементів продукту в один?	Ні, продукт є завершеним

Продовження таблиці 5.17

<i>№ n/n</i>	<i>Запитання</i>	<i>Відповідь</i>
4	Чи можна нерухомі частини продукту зробити рухомими і навпаки?	Ні, відеокамери виставлені та налаштовані для отримання чітких зображень.
5	Яким має бути ідеальний продукт?	Високодостовірним, якісним, довговічним.
6	Що відбудеться, якщо вилучити цей продукт? Чим його можна замінити?	Його можна замінити професійним дефектоскопістом
7	Яким цей продукт був у минулому?	Мав меншу достовірність та швидкість розпізнавання дефектів
8	На розвиток яких функцій було спрямоване удосконалення продукту?	На покращення достовірності та швидкості визначення дефектів на металевих поверхнях.

Можемо зробити висновок, що продукт є високотехнологічним і покращити його можна змінивши відеокамери з більшою роздільною здатністю які надає зображення, ці дослідження дозволять покращити розпізнавання дефектів та їх характеристик.

5.3. Розроблення ринкової стратегії розвитку

Для розроблення ринкової стратегії необхідно почати з визначення цільових груп потенційних споживачів (табл.5.18)

Таблиця 5.18 Вибір цільових груп потенційних споживачів [49]

<i>№ n/n</i>	<i>Опис профілю цільової групи потенційних клієнтів</i>	<i>Готовність споживачів сприйняти продукт</i>	<i>Орієнтовний попит в межах цільової групи (сегменту)</i>	<i>Інтенсив- ність конкурен- ції в сегменті</i>	<i>Простот авходу у сегмент</i>
1	Підприємства, що виробляють металеві вироби	+	+	Висока	+
2	Компанії, що спеціалізуються на контролі якості металевих виробів	+	+	Висока	-

Після опису цільових груп потенційних клієнтів можна обрати ту яка найбільше підходить. В першу чергу до уваги приймається готовність цільової групи сприйняти продукт, тому основними є підприємства, що виробляють металеві вироби.

Для подальшої роботи з цільовими групами потрібно визначитись з базовою стратегією розвитку (табл. 5.19)

Таблиця 5.19 Визначення базової стратегії розвитку [49]

<i>Обрана альтернатива розвитку проекту</i>	<i>Стратегія охоплення ринку</i>	<i>Ключові конкурентоспроможні позиції відповідно до обраної альтернативи</i>	<i>Базова стратегія розвитку*</i>
Концентрація на потребах цільового сегменту ринку.	Стратегія недиференційованого маркетингу	Використання інновацій та адаптація до вимог ринку	Стратегія спеціалізації

Проаналізувавши таблицю 5.19 можна зробити висновок, що через існування на ринку сильних гравців обираємо стратегію спеціалізації. Необхідно використовувати інновації для забезпечення високої якості продукції.

Далі потрібно визначитись із базовою стратегією конкурентної поведінки (табл. 5.20).

Таблиця 5.20. Визначення базової стратегії конкурентної поведінки [49]

<i>Чи є проект «першопрохідцем» на ринку?</i>	<i>Чи буде компанія шукати нових споживачів, або забирати існуючих у конкурентів?</i>	<i>Чи буде компанія копіювати основні характеристики товару конкурента, і які?</i>	<i>Стратегія конкурентної поведінки*</i>
Ні	Шукати нових споживачів та забирати існуючих у конкурентів.	Ні	Стратегія лідера

Проаналізувавши таблицю 5.20 можемо зробити висновок, що оскільки проєкт не є першопрохідцем, але має суттєві переваги над продуктом-аналогом, можна обрати стратегію лідера. Це можливо оскільки використовується дешевша технологія при кращій якості.

Наступним кроком потрібно визначитись із стратегією позиціонування, яка формується на основі вимог клієнтів (табл. 5.21).

Таблиця 5.21. Визначення стратегії позиціонування [49]

<i>n/n</i>	<i>Вимоги до товару цільової аудиторії</i>	<i>Базова стратегія розвитку</i>	<i>Ключові конкурентоспроможні позиції Власного стартап-проєкту</i>	<i>Вибір асоціацій, які мають сформувану комплексну позицію власного проєкту (три ключових)</i>
1	Достовірність	Стратегія спеціалізації	Система з високою достовірністю	Високодостовірна
2	Швидкодія	Стратегія спеціалізації	Система з високою швидкістю	Здатність швидко визначати дефекти на металевих поверхнях
3	Висока якість	Стратегія Спеціалізації	Якість	Надійна

Висновок: стартап-проєкт буде працювати за стратегією спеціалізації, оскільки його основною метою є підвищення достовірності та швидкодії автоматичного визначення дефектів та їх характеристик на зображеннях.

5.4. Розроблення маркетингової програми стартап-проєкту

При розробці маркетингової програми слід почати із визначення ключових переваг концепції товару (табл. 5.22).

Таблиця 5.22. Визначення ключових перевагконцепції потенційного товару [49]

<i>№ n/n</i>	<i>Потреба</i>	<i>Вигода, яку пропонує товар</i>	<i>Ключові переваги перед конкурентами</i>
1	Необхідність підвищення швидкості контролю	Відносно дешева методика досліджень, яка дозволить досягти збільшення швидкості	Висока достовірність та швидкість контролю, можливість розпізнавання дефектів та їх параметрів
2	Необхідність підвищення достовірності контролю	Надійна технологія, яка дозволить підвищити достовірність	
3	Необхідність підвищення точності розпізнавання видів та характеристик дефектів	Можливість розпізнавання дефектів та їх параметрів	

З даних наведених в таблиці 5.22 можна зробити висновок, що перевагами проекту є достовірність, швидкість діагностики та можливість розпізнавання об'єктів та їх параметрів.

Наступним кроком необхідно визначити цінові межі, якими необхідно керуватися при встановленні ціни на потенційний товар (табл. 5.23).

Таблиця 5.23. Визначення меж встановлення ціни [49]

<i>Рівень цін на товари-замінники</i>	<i>Рівень цін на товари-аналоги</i>	<i>Рівень доходів цільової групи споживачів</i>	<i>Верхня та нижня межі встановлення ціни на товар/послугу</i>
150000-200000	150000-200000	100000-1000000	100000-150000

Для стартап-проекту було обрано середню цінову категорію, оскільки висока ціна може не задовольнити клієнтів.

Важливу роль у реалізації стартапу відіграє ефективна команда. Команда (від лат. *Commando* – «доручаю») – це об'єднання однодумців, які керуються спільною метою. Відомості, які необхідно прояснити, отримуючи завдання на формування проектної команди для стартапу наведено в таблиці 5.24[52].

Опис команди стартапу представлено в таблиці 5.25.

Таблиця 5.24. Питання, що потребують відповідей до початку формування команди стартапу [50]

Питання	Пояснення
В які терміни команда повинна бути сформована?	Команду потрібно сформувати за два місяці
Хто ключові люди в створюваній команді (тобто співробітники, без яких робота неможлива або неефективна)?	Інженер-технолог, маркетолог, ІТ-спеціаліст, інженер-конструктор
Чи є можливість використовувати для пошуку персоналу додаткові джерела?	Так, можна звертатись в кадрове агентство або до рекрутера-фрілансера

Продовження таблиці 5.24

Питання	Пояснення
Яка роль у кожного члена команди?	Маркетолог повинен займатись просуванням продукту, інженери – проводити дослідження та розрахунки, ІТ-спеціаліст – алгоритм розпізнавання об'єктів та ін.
Як мотивувати членів команди?	Можливість отримання щомісячної премії за виконання поставлених завдань

Таблиця 5.25. Початкові вкладення у стартап проект

<i>Стадія стартапу</i>	<i>Завдання</i>	<i>Члени команди</i>	<i>Освіта</i>	<i>Досвід роботи</i>	<i>Спеціалізовані знання</i>	<i>Витрати, тис. грн</i>
Передпосівна	Розробка ідеї без розробленого механізму її реалізації Перевірка чи подобається розроблена ідея майбутнім споживачам	Стешенко Ярослав, Протасов Анатолій	ІТ-спеціаліст, інженер з неруйнівного контролю	20 років	Знання в сфері неруйнівного контролю	-

Продовження таблиці 5.25

<i>Стадія старту</i>	<i>Завдання</i>	<i>Члени команди</i>	<i>Освіта</i>	<i>Досвід роботи</i>	<i>Спеціалізовані знання</i>	<i>Витрати, тис. грн</i>
Посівна	Дослідження ринку, опитування потенційних покупців та клієнтів, пошук інвесторів	Стешенко Ярослав, Протасов Анатолій	ІТ-спеціаліст, інженер з неруйнівного контролю	20 років	Знання в сфері неруйнівного контролю	10000
Створення прототипу	Провести нові дослідження для виявлення можливості покращення достовірності та швидкості визначення дефектів, розробка програми	Стешенко Ярослав, Протасов Анатолій, Момот Сергій	ІТ-спеціаліст, інженер з неруйнівного контролю, Інженер-технолог	20 років, 2 роки	Знання в сфері неруйнівного контролю; Знання в сфері розробки програмного забезпечення;	100000

Кінець таблиці 5.25

<i>Стадія старту</i>	<i>Завдання</i>	<i>Члени команди</i>	<i>Освіта</i>	<i>Досвід роботи</i>	<i>Спеціалізовані знання</i>	<i>Витрати, тис. грн</i>
Закрита бета-версія	Створити готовий, життєздатний продукт, перевірити його якісні показники	Кравченко Петро	Маркетолог	5 років	Знання в сфері маркетингу	120000
Ведення бізнесу	Збільшити кількість реклами та продажів, залучення нових клієнтів	Стешенко Ярослав, Протасов Анатолій, Момот Сергій, Кравченко Петро	ІТ-спеціаліст інженер з Неруйнів-ного контролю Інженер-технолог, Маркетолог	20 років, 2 роки, 5 років	Знання в сфері неруйнівного контролю, Знання в сфері розробки програмного забезпечення; Знання в сфері маркетингу. Знання в сфері менеджменту	100000

Отже, в загальному команда складається з інженера-технолога, інженера з неруйнівного контролю, ІТ-спеціаліста та маркетолога. Більшість членів команди компетентні та мають великий досвід роботи.

Складемо календарний план-графік підготовки стартапу (таблиця 5.26).

Таблиця 5.26. Календарний план-графік підготовки стартапу

Стадія стартапу	Період запуску (за місяцями з початку підготовки проекту)					Вартість стадії, грн
	1	2	3	4	5	
Передпосівна	01.01.22 01.02.22					-
Посівна		01.02.22 01.03.22				10000
Прототипування			01.03.22 10.06.22			100000
Закрита бета-версія				20.06.22 01.08.22		120000
Ведення бізнесу					3 01.08.22	200000
Разом						430000

Отже, з таблиці 5.26 можемо зробити висновок, що на реалізацію проекту знадобиться 8 місяців та 430 тис. грн. Найбільш дорогим етапом є введення бізнесу через його довготривалість. Розподілимо частки між авторами стартапу на основі запропонованого методу Frank Demmler, професором підприємництва в бізнес-школі при Carnegie Mellon University. Визначимо важливість кожного фактора та внесок кожного з авторів (табл. 5.27).

Таблиця 5.27. Оцінювання важливості кожного фактора і

внеску кожного учасника [52]

Фактор	Вага	Автор 1	Автор 2
Участь у розробленні ідеї	9	10	6
Участь у підготовці бізнес-плану	7	7	8
Компетентність. учасника	10	10	10
Залученість і ризику учасника	7	8	9
Обов'язки та відповідальність учасника	10	9	10
Разом (вага * внесок автора)		385	764
Відсоток		50,4 %	49,6 %

Можемо зробити висновок що обоє авторів компетентними і приймали активну участь у створенні проекту. Частка стартапу першого автора складає 50,4 %, частка другого – 49,6 %. Отже, автори приблизно однаково впливали на створення продукту.

Далі слід визначити оптимальну систему збуту (табл. 5.28), це необхідно для того, щоб підвищити ефективність збуту. Канали збуту, виконують ряд функцій, зокрема:

- підвищують ступінь поінформованості споживача про товари і послуги компанії;
- допомагають оцінити ціннісні пропозиції компанії;
- дозволяють споживачеві купувати певні товари та послуги;
- знайомлять споживача з ціннісними пропозиціями;
- забезпечують після-продажне обслуговування.

Таблиця 5.28. Формування системи збуту [49]

<i>№ n/n</i>	<i>Специфіка закупівельної поведінки цільових клієнтів</i>	<i>Функції збуту, які має виконувати постачальник товару</i>	<i>Глибина каналу збуту</i>	<i>Оптимальн асистема збуту</i>
1	Замовлення заздалегідь	Налагоджування та тестування	Нульового рівня	Пряма
2	Регулярні поставки	Налагоджування та встановлення, перевірка наявного обладнання, тестування	Нульового рівня	Пряма

За даними наведені в таблиці 5.28 робимо висновок, що виробник буде продавати товар безпосередньо кінцевому споживачеві, оскільки глибина каналу збуту нульового рівня. Виробник буде контролювати регулярність поставок та контроль обладнання.

Останньою складової маркетингової програми стартап-проекту є розроблення концепції маркетингових комунікацій, що спирається на попередньо визначену специфіку поведінки клієнтів та обрану основу для позиціонування (табл.5.29).

Маркетингові комунікації – це одна з основних і складних елементів **комплексу маркетингу** організації. Маркетинговими комунікаціями можна назвати повідомлення і засоби масової інформації, спрямовані на передачу інформації про продукт і встановлення зв'язку з цільовою аудиторією, ринком.

Таблиця 5.29. Концепція маркетингових комунікацій [50]

<i>Специфіка поведінки цільових клієнтів</i>	<i>Канали комунікацій, якими користуються цільові клієнти</i>	<i>Ключові позиції, обрані для позиціонування</i>	<i>Завдання рекламного повідомлення</i>	<i>Концепція рекламного звернення</i>
Потребують автоматизованого процесу аналізу термографічних зображень при оптимальній ціні, тому порівнюють конкурентні пропозиції	Інтернет, журнали, фахові видання, соціальні мережі, месенджери	Висока якість, достовірність та швидкість, відносно низька вартість	Показати покупцю перевагу над конкурентами та можливість економії після придбання продукту	Реклама функцій системи та її основних характеристик

Дані занесені до таблиці 5.29 - це ринкова програма, що складається із концепції товару, просування, збуту та аналіз ціноутворення, базується на цінностях та потребах клієнтів, конкурентних перевагах ідеї, стані ринкового середовища та на відповідній альтернативі ринкової поведінки.

Необхідно визначити початкові вкладення для розвитку стартап-проєкту (табл. 5.30). Початкові інвестиції – це реальна вартість проєкту з урахуванням результатів від продажу старого обладнання та сплати податків.

Таблиця 5.30. Початкові вкладення на запуск стартап-проєкту [52]

<i>Види витрат</i>	<i>Вартість</i>
НДДКР	5000
Захист прав на об'єкти інтелектуальної власності	10 000
Створення прототипу, досліді	10 000
Просування	100 000
Витрати на команду	30 000
Закупівля обладнання	51 000
Орієнтована собівартість першого продукту	100000
РАЗОМ	216 000
Витрати, що бере на себе стартапер	66 000
Необхідні інвестиції для запуску стартапу	150 000

Проаналізувавши таблицю 5.30 робимо висновок, що необхідно отримати інвестиції у розмірі 150 000 грн для створення прототипу, просування та оплати роботи працівників.

Планові фінансово-економічні показники проєкту наведені в таблиці 5.31, вони потрібні для приблизної оцінки прибутків за рік.

Таблиця 5.31. Планові фінансово-економічні показники

	Показник	Періоди (по місяцях)											Всього за рік	
		1	2	3	4	5	6	7	8	9	10	11		12
1	Обсяг продажу продукції натуральних показниках в	5	5	6	7	7	7	8	8	8	9	9	10	89

Продовження таблиці 5.31

	Показник	Періоди (по місяцях)											Всього за рік	
		1	2	3	4	5	6	7	8	9	10	11		12
2	Собівартість одиниці продукції, тис. грн.	1 5	1 5	1 5	1 5	1 5	1 5	1 5	1 5	1 5	1 5	1 5	1 5	180
3	Собівартість виробництва продукції, тис. грн. (3 = 1 · 2)	7 5	7 5	9 0	1 5	1 5	1 5	1 0	1 2	1 2	1 2	1 3	1 3	1335
4	Обсяг реалізації продукції в натуральних показниках	5	5	6	7	7	7	8	8	8	9	9	1 0	89
5	Ціна реалізації продукції без ПДВ, тис. грн.	2 0	2 0	2 0	2 0	2 0	2 0	2 0	2 0	2 0	2 0	2 0	2 0	240
6	Виручка від реалізації продукції без ПДВ, тис. грн. (6 = 4 · 5)	1 0 0	1 0 0	1 2 0	1 4 0	1 4 0	1 4 0	1 6 0	1 6 0	1 6 0	1 8 0	1 8 0	2 0 0	1780
7	Податок на додану вартість (ПДВ), тис.грн. (7=6/5)	5	5	6	7	7	7	8	8	8	9	9	1 0	89
8	Валовий прибуток (8 = 6 – 3)	2 5	2 5	3 0	3 5	3 5	3 5	4 0	4 0	4 0	4 5	4 5	5 0	445
9	Податок на прибуток (9=8*0,20 (20 %))	5	5	6	7	7	7	8	8	8	9	9	1 0	89
10	Чистий прибуток (10 = 8 – 9)	2 0	2 0	2 4	2 8	2 8	2 8	3 2	3 2	3 2	3 6	3 6	4 0	356

З таблиці 5.32 можемо зробити висновок, що при продажі 89 систем діагностики за рік з собівартістю 15 тис. грн. податки на їх продаж складуть 89 тис. грн., а орієнтовний чистий прибуток при цьому складе 356 тис. грн., що задовольняє потреби стартапу.

Для узгодження кошторису витрат на виробництво за економічними елементами з кошторисом витрат за калькуляційними статтями складається зведений план витрат на виробництво. Він також дозволяє перевірити правильність розрахунків собівартості продукції (робіт, послуг).

Розглянемо зведений план витрат на запуск виробництва продукції (табл.5.32).

Таблиця 5.32. Зведений план витрат на запуск виробництва продукції

<i>Найменування</i>	<i>Пояснення</i>	<i>Вартість тис. грн.</i>
Витрати на придбання обладнання та устаткування	Витрати на придбання обладнання	200
Сировина, основні матеріали	Вартість сировини та матеріалів	100
Комплектуючі	Витрати на комплектуючі продукту	10
Паливо та електроенергія на технологічні цілі	Витрати на електроенергію, а також на паливо, необхідні для запуску проектної потужності виробництва	30
Оплата праці промислово-виробничого персоналу	Витрати на заробітну плату та соціальні відрахування	60
Освоєння та запуск виробництва	Витрати на пусконаладжувальні роботи, запуск виробництва	30
Разом:		430

Отже, зведений план витрат на запуск виробництва продукції показує, що для реалізації та випуску продукції необхідно 430 тис. грн.

Далі складемо план маркетингу (табл. 5.33), він складається з метою опису реальних ринкових можливостей та цілей стартапу, а також для того щоб узгодити варіанти рекламних платформ на яких буде розміщуватись реклама готового продукту. Маркетинг стартапу – це поєднання інструментів та заходів із ознайомлення цільової аудиторії з ідеєю продукту, просування ідеї та безпосередньо товару на ринок з метою збільшення зацікавленості та прихильності потенційних клієнтів, залучення споживачів, інвесторів тощо.

Таблиця 5.33. План маркетингу [50]

<i>№ n/n</i>	<i>Назва розділу</i>	<i>Елементи наповнення розділу (в дану колонку слід записати результат)</i>
1.	Цілі і завдання на найближчий рік	Просування продукції , збільшення клієнтської бази
2.	Місія та цінності стартапу	Орієнтація на створення якісного продукту
3.	Цільова аудиторія	Підприємці з середнім та високим рівнем доходів, віком 25-60 років.
4.	Аналіз ситуації	Автоматизована система неруйнівного контролю та діагностики металевих поверхонь за результатами активного візуально-оптичного контролю з використанням нейронних мереж, вона має високу достовірність та швидкодію. Просування стартапу здійснюється через фахові видання. Проект є прибутковим оскільки задовольняє потребу клієнтів у якості.

Продовження таблиці 5.33

<i>№ n/n</i>	<i>Назва розділу</i>	<i>Елементи наповнення розділу (в дану колонку слід записати результат)</i>
5.	Ціни і стратегія позиціонування	Стартап позиціонує себе як доступну та якісну систему для неруйнівного контролю металевих поверхонь
6.	План просування	Запустити таргетенгову рекламу та офлайн рекламу для залучення старших груп споживачів.
7.	Маркетингові активи	Таргет в фейсбук, статті в фахових виданнях
8.	Конверсійна стратегія	Конверсія в рекламі
9.	План збільшення продажів	Збільшити кількість функцій, які пропонуються споживачеві. Створити програму лояльності для збільшення кількості повторних клієнтів
10.	Фінансові прогнози	Потрібні початкові інвестиції в розмірі 150 тис. грн

Проаналізувавши таблицю 5.33 можемо зробити висновок, що просування продукції є важливою та однією з основних цілей стартап-проекту, необхідно вкладати кошти в рекламу в усіх можливих джерелах та створити програму лояльності для постійних клієнтів. Необхідно позиціонувати проект як якісну та більш доступну альтернативу наявним на ринку продуктам.

Висновки до розділу

Проведене у роботі дослідження, результатом якого є покращення достовірності визначення дефектів можна подати у вигляді бізнес моделі для залучення додаткових інвестиції на розробку системи.

Ефективність реалізації стартапу залежить від трьох компонентів: ідеї,

команди та фінансування. Без інноваційної ідеї стартап, перестає бути стартапом, і має характеристики звичайного бізнесу. Відсутність фінансування може значно затримати реалізацію стартапу, що призводить до появи конкурентів та втрати бажаної частки на ринку. Однак, не менш важливу роль у реалізації стартапу відіграє ефективна команда.

Першим кроком до комерційної реалізації є формування ідеї проєкту та інформаційної та морфологічної карти. Правильне формування ідеї проєкту важливе для наступних етапів розробки.

Важливо дослідити можливості стартапу, також було означено основний ризик для стартапу – конкуренція, та визначено допустиму реакцію компанії – підвищення надійності системи неруйнівного контролю металевих поверхонь. Основною можливістю є збільшення попиту, що може допомогти збільшити кількість клієнтів, а для забезпечення цього, необхідно покращувати характеристики системи. Оскільки на ринку спостерігається чиста та невелика конкуренція можна зробити висновок щодо хороших можливостей роботи на ринку. Існують виходи на національний ринок, використання стартапу можливе у неруйнівному контролі.

Проаналізувавши стартап-проєкт можна зробити висновок про хороші можливості для виходу на ринок через наявність великого попиту на продукцію вітчизняних виробників серед споживачів. Також спостерігається позитивна динаміка росту ринку. Єдиним обмеженням для виходу на ринок є наявність сертифікатів та дозвільних документів.

У реалізації даного стартап-проєкту важливу роль виконає маркетингова складова, яка за рахунок концентрації на перевагах стартап-проєкту дає перевагу над продуктами конкурентів. Вся реклама повинна бути спрямована на подачу потенційним клієнтам інформації, необхідні початкові інвестиції у розмірі 150 тис. грн.

Отже проаналізувавши всі аспекти ринку, можемо зробити висновок, що проєкт можливо реалізувати. Але для цього необхідно мати переваги над продуктами прямих конкурентів, та вміло їх подавати.

ВИСНОВКИ

1. Встановлено, що основними проблемами візуальної дефектоскопії є обмежена здатність спостерігача розпізнавати незначні або складно помітні дефекти. Людський фактор, такий як втома, неправильне освітлення або зорові обмеження, можуть призводити до пропуску дефектів або неправильної їх інтерпретації. Визначено, що одним з напрямів удосконалення візуальної дефектоскопії є використання візуально-оптичного методу та нейромережевих технологій.

2. Проаналізовано існуючі методи сегментації зображень з розпізнаванням дефектів на зображеннях. Встановлено, що найкращим варіантом є використання методу сегментації зображень на основі згорткової нейронної мережі. Такий тип мережі може працювати з великими наборами даних, здатний ефективно навчатись за допомогою глибокого навчання, автоматично вибирати найбільш релевантні ознаки зображення для сегментації, що робить цей метод більш ефективним за традиційні методи. На основі аналізу чотирьох різних нейронних мереж, таких як: FCN, DeepLab, LinkNet та U-Net, було вибрано мережу U-Net, так як на сьогоднішній день вона показує найкращі результати в завданнях сегментації зображень.

3. Розроблено алгоритмічне та програмне забезпечення, що дозволяє опрацювати зображення нейронною мережею, виявляючи на них дефекти чотирьох різних класів. Також програмне забезпечення дозволяє виділити дефекти контуром певного кольору та формою.

4. Проведено тестування запропонованої системи на реальних даних та отримані такі результати: коефіцієнт Дайса – 69% та IOUScore – 53%. Враховуючи незбалансовану кількість зображень з різними дефектами та кількість дефектів, які треба класифікувати, результати можна вважати хорошими.

5. Проаналізовано роботу системи з використанням різних бекбонів та різних порогів бінаризації масок. Виявлено, що бекбони ResNet34, ResNet50,

ResNet101 та ResNet152, які мають більше параметрів ніж у ResNet18, не дають кращих результатів, тому кращим варіантом буде використовувати бекбон ResNet18, який має найменший час навчання за рахунок малої кількості параметрів. Щодо порогів бінаризації, то для досягнення найкращих результатів сегментації зображень поверхневих дефектів сталі мережею U-Net, навченої на використаному у дослідженні наборі даних, оптимальним є значення порогу бінаризації на рівні 0,5...0,75.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

- [1] Сторожик Д. В. Технології опрацювання зображень на основі комплексування даних (Огляд) / Д.В. Сторожик, А.Г. Протасов // Технічна діагностика та неруйнівний контроль. – 2022. – № 4. – С. 17–26.
- [2] Петрик, В. Ф. Бездротові технології в автоматизації неруйнівного контролю / В. Ф. Петрик, А. Г. Протасов, Р. М. Галаган, О. В. Муравйов, А. С. Момот // Вчені записки ТНУ імені В. І. Вернадського. Серія: технічні науки. – 2021. – Том 32 (71), № 5. – С. 25-29.
- [3] Application of YOLOX deep learning model for automated object detection on thermograms / I. O. Skladchykov [та ін.] // Information extraction and processing. – 2022. – № 50. – С. 69–77.
- [4] Єрмоленко В. А. Глобалізація і безпека розвитку : навч. посіб. / В. А. Єрмоленко. – Черкаси : Вертикаль, 2012. – 336 с.
- [5] A review of non-destructive testing (NDT) techniques for defect detection: application to fusion welding and future wire arc additive manufacturing processes / Masoud Shaloo [та ін.] // Materials. – 2022. – Том. 15, № 10. – С. 3697.
- [6] Живкович А. В. Современные технологии бесконтактного измерения температуры / А. В. Живкович, А. В. Муравьев // Материалы XVI Международной научно-практической конференции «Динамика научных исследований - 2020», 07-15 июля 2020, Пшемьсль, Польша. – Przemysł : Nauka i studia, 2020. – Том. 7. – С. 110-115.
- [7] Кучеренко О. К. Ахроматизація та атермалізація об'єктивів інфрачервоної техніки / О. К. Кучеренко, О. В. Муравйов, В. М. Тягур // Наукові вісті НТУУ «КПІ». – 2012. – вип. №5. – С. 114-117.
- [8] Муравьев А. В. Композиции атермализованных трехкомпонентных инфракрасных объективов / А. В. Муравьев, О. К. Кучеренко // Наука и техника. – 2015. – № 4. – С. 32-37.
- [9] Mazur I. Quality Control system for a hot-rolled metal surface / I. Mazur, T.

- Koinov // *Frattura ed integrità strutturale*. – 2016. – Том. 10, № 37. – С. 287–296.
- [10] Detection of surface defects on sheet metal parts by using one-shot deflectometry in the infrared range / Zoltán Sárosi [та ін.] // *Inframation 2010 : IWF, ETH Zurich*. – [S. l.], 2010.
- [11] Sun Q. Detection of surface defects on steel strips based on singular value decomposition of digital image / Qianlai Sun, Jianghui Cai, Zhiyi Sun // *Mathematical problems in engineering*. – 2016. – С. 1–12.
- [12] Automated visual inspection of rolled metal surfaces / Timo Piironen [та ін.] // *Machine vision and applications*. – 1990. – № 3. – С. 247–254.
- [13] Segmentation of rust defects on painted steel surfaces by intelligent image analysis [Электронний ресурс] / Roman Vorobel [та ін.] // *Automation in construction*. – 2021. – № 123. – С. 103515.
- [14] Localization and segmentation of metal cracks using deep learning [Электронний ресурс] / Yasir Aslam [та ін.] // *Journal of ambient intelligence and humanized computing*. – 2020.
- [15] Sharma M. The Amalgamation of the Object Detection and Semantic Segmentation for Steel Surface Defect Detection [Электронний ресурс] / Mansi Sharma, Jongtae Lim, Hansung Lee // *Applied Sciences*. – 2022. – Том. 12, № 12. – С. 6004.
- [16] Neogi N. Review of vision-based steel surface inspection systems [Электронний ресурс] / Nirbhar Neogi, Dusmanta K. Mohanta, Pranab K. Dutta // *EURASIP journal on image and video processing*. – 2014. – № 1.
- [17] Steger C. *Machine vision algorithms and applications* / Carsten Steger, Markus Ulrich, Christian Wiedemann. – [S. l.] : Wiley & Sons, Incorporated, John, 2017. – 516 p.
- [18] Hornberg A. *Handbook of machine and computer vision: the guide for developers and users* / Alexander Hornberg. – [S. l.] : Wiley & Sons, Limited, John, 2017. – 860 p.
- [19] Deep-Learning-Based small surface defect detection via an exaggerated local

- variation-based generative adversarial network [Електронний ресурс] / Jian Lian [та ін.] // IEEE transactions on industrial informatics. – 2020. – Том. 16, № 2. – С. 1343–1351.
- [20] Improved Sobel algorithm for defect detection of rail surfaces with enhanced efficiency and accuracy [Електронний ресурс] / Tian Shi [та ін.] // Journal of central south university. – 2016. – Том. 23, № 11. – С. 2867–2875.
- [21] Lin H.-I. Image data assessment approach for deep learning-based metal surface defect-detection systems [Електронний ресурс] / Hsien-I. Lin, Fauzy Satrio Wibowo // IEEE access. – 2021. – № 9. – С. 47621–47638.
- [22] Shreya S. R. Design of machine vision system for high speed manufacturing environments [Електронний ресурс] / S. R. Shreya, C. Sahiti Priya, G. S. Rajeshware // 2016 IEEE annual india conference (INDICON), Bangalore, India, 16–18 December 2016. – [S. 1.], 2016.
- [23] Long J. Fully convolutional networks for semantic segmentation [Електронний ресурс] / Jonathan Long, Evan Shelhamer, Trevor Darrell // 2015 IEEE conference on computer vision and pattern recognition (CVPR), Boston, MA, USA, 7–12 June 2015. – [S. 1.], 2015.
- [24] DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs [Електронний ресурс] / Liang-Chieh Chen [та ін.] // IEEE transactions on pattern analysis and machine intelligence. – 2018. – Том. 40, № 4. – С. 834–848.
- [25] Chaurasia A. LinkNet: exploiting encoder representations for efficient semantic segmentation [Електронний ресурс] / Abhishek Chaurasia, Eugenio Culurciello // 2017 IEEE visual communications and image processing (VCIP), St. Petersburg, FL, 10–13 December 2017. – [S. 1.], 2017.
- [26] Ronneberger O. U-Net: convolutional networks for biomedical image segmentation [Електронний ресурс] / Olaf Ronneberger, Philipp Fischer, Thomas Brox // Lecture notes in computer science. – Cham, 2015. – С. 234–241.
- [27] Стешенко Я.В. Огляд ефективності архітектур нейронних мереж для

- автоматизованої сегментації зображень / Стешенко Я.В., Момот А.С. // Ефективність та автоматизація інженерних рішень у приладобудуванні. – 2022. – № 18. – С. 226-229.
- [28] Esophagus segmentation in computed tomography images using a u-net neural network with a semiautomatic labeling method [Електронний ресурс] / Xiao Lou [та ін.] // IEEE access. – 2020. – № 8. – С. 202459–202468.
- [29] Сторожик Д. В. Комплексування мультиспектральних зображень, як метод підвищення їх інформативності при бінарній сегментації / Д. В. Сторожик, О. В. Муравйов, А. Г. Протасов, В. Г. Баженов, Г. А. Богдан // Наукові вісті КПП. – 2020. № 2. – С. 82-87.
- [30] UNet++: a nested u-net architecture for medical image segmentation [Електронний ресурс] / Zongwei Zhou [та ін.] // Deep learning in medical image analysis and multimodal learning for clinical decision support. – Cham, 2018. – С. 3–11.
- [31] DoubleU-Net: a deep convolutional neural network for medical image segmentation [Електронний ресурс] / Debesh Jha [та ін.] // 2020 IEEE 33rd international symposium on computer-based medical systems (CBMS), Rochester, MN, USA, 28–30 July 2020. – [S. l.], 2020.
- [32] Hu J. Squeeze-and-Excitation networks [Електронний ресурс] / Jie Hu, Li Shen, Gang Sun // 2018 IEEE/CVF conference on computer vision and pattern recognition (CVPR), Salt Lake City, UT, 18–23 June 2018. – [S. l.], 2018.
- [33] Ibtehaz N. MultiResUNet : Rethinking the U-Net architecture for multimodal biomedical image segmentation [Електронний ресурс] / Nabil Ibtehaz, M. Sohel Rahman // Neural networks. – 2020. – № 121. – С. 74–87.
- [34] LeCun Y. Deep learning [Електронний ресурс] / Yann LeCun, Yoshua Bengio, Geoffrey Hinton // Nature. – 2015. – Том. 521, № 7553. – С. 436–444.
- [35] Efficient and visualizable convolutional neural networks for COVID-19 classification using Chest CT [Електронний ресурс] / Aksh Garg [та ін.] // Expert systems with applications. – 2022. – № 195. – С. 116540.
- [36] Densely connected convolutional networks [Електронний ресурс] / Gao

- Huang [та ін.] // 2017 IEEE conference on computer vision and pattern recognition (CVPR), Honolulu, HI, 21–26 July 2017. – [S. 1.], 2017.
- [37] Semi-CNN architecture for effective spatio-temporal learning in action recognition [Електронний ресурс] / Mei Chee Leong [та ін.] // Applied sciences. – 2020. – Том. 10, № 2. – С. 557.
- [38] Deep residual learning for image recognition [Електронний ресурс] / Kaiming He [та ін.] // 2016 IEEE conference on computer vision and pattern recognition (CVPR), Las Vegas, NV, USA, 27–30 June 2016. – [S. 1.], 2016.
- [39] Joseph F. J. J. Keras and TensorFlow: A Hands-On Experience [Електронний ресурс] / Ferdin Joe John Joseph, Sarayut Nonsiri, Anop Monsakul // Advanced deep learning for engineers and scientists. – Cham, 2021. – С. 85–111.
- [40] Ketkar N. Introduction to keras [Електронний ресурс] / Nikhil Ketkar // Deep learning with python. – Berkeley, CA, 2017. – С. 97–111.
- [41] Momot A. Deep learning automated data analysis of security infrared cameras / A. Momot, I. Skladchykov // Slovak international scientific journal. – 2021. – №52. – pp. 13–16.
- [42] Momot A. Automation of ultrasound breast cancer images classification using deep neural networks / A. Momot, R. Galagan, M. Zaboluiieva // Sciences of Europe. – 2022. – №96. – pp. 38–41.
- [43] Severstal: steel defect detection | kaggle [Електронний ресурс] // Kaggle: Your Machine Learning and Data Science Community. – Режим доступу: <https://www.kaggle.com/competitions/severstal-steel-defect-detection/data>
- [44] Haibo He. Learning from imbalanced data [Електронний ресурс] / Haibo He, E. A. Garcia // IEEE transactions on knowledge and data engineering. – 2009. – Том. 21, № 9. – С. 1263–1284.
- [45] Semantic segmentation deep learning for extracting surface mine extents from historic topographic maps [Електронний ресурс] / Aaron E. Maxwell [та ін.] // Remote sensing. – 2020. – Том. 12, № 24. – С. 4145.
- [46] Haibo He. Learning from imbalanced data [Електронний ресурс] / Haibo He,

- E. A. Garcia // IEEE transactions on knowledge and data engineering. – 2009. – Том. 21, № 9. – С. 1263–1284.
- [47] Data-Efficient domain adaptation for semantic segmentation of aerial imagery using generative adversarial networks [Електронний ресурс] / Bilel Benjdira [та ін.] // Applied sciences. – 2020. – Том. 10, № 3. – С. 1092.
- [48] Муравйов О. В. Автоматизація методу термографічної діагностики патологій організму людини / О. В. Муравйов, В. Ф. Петрик, Ю. Ю. Лисенко, Г. А. Богдан, А. В. Наконечная // Таврійський науковий вісник. Серія: Технічні науки. – 2022. – №1. – С. 47-53.
- [49] Розроблення стартап-проекту [Електронний ресурс] : Методичні рекомендації до виконання розділу магістерських дисертацій для студентів інженерних спеціальностей / За заг. ред. О.А. Гавриша. – Київ : НТУУ «КПІ», 2016. – 28 с.
- [50] Гавриш, О. А. Розробка стартап-проектів. Конспект лекцій [Електронний ресурс] : навчальний посібник для студентів спеціальностей 151 – «Автоматизація та комп'ютерно-інтегровані технології» та 152 – «Метрологія та інформаційно-вимірвальна техніка» / О. А. Гавриш, К. О. Бояринова, К. О. Копішинська ; КПІ ім. Ігоря Сікорського. – Електронні 95 текстові данні (1 файл: 2,88 Мбайт). – Київ : КПІ ім. Ігоря Сікорського, 2019. – 188 с. – Назва з екрана.
- [51] Галаган Р.М. Тестування нейромережових модулів системи теплової дефектометрії за допомогою імітаційного моделювання / [Р. М. Галаган, А. С. Момот, А. Г. Протасов та ін.]. // Вчені записки ТНУ імені В.І. Вернадського. Серія: Технічні науки. – 2022. – №6. – с. 49–55.
- [52] Гавриш, О. А. Розробка стартап-проектів: практикум: навчальний посібник для студентів спеціальностей 151 – «Автоматизація та комп'ютерно-інтегровані технології» та 152 – «Метрологія та інформаційно-вимірвальна техніка» / О. А. Гавриш, К. О. Бояринова, К. О. Копішинська ; КПІ ім. Ігоря Сікорського. – Електронні текстові данні (1 файл: 2,11 Мбайт). – Київ : КПІ ім. Ігоря Сікорського, 2019. – 116 с.