

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ
ІМЕНІ ІГОРЯ СІКОРСЬКОГО»
Інженерно-хімічний факультет**

(повна назва інституту/факультету)

Кафедра технічних та програмних засобів автоматизації
(повна назва кафедри)

«На правах рукопису»
УДК _____

«До захисту допущено»
Завідувач кафедри
_____ Віталій ЦАПАР
« ____ » _____ 20__ р.

Магістерська дисертація

на здобуття ступеня магістра

за освітньо-науковою програмою «Автоматизація та комп'ютерно-інтегровані
технології »

зі спеціальності 174 – Автоматизація, комп'ютерно-інтегровані технології та
робототехніка

(код і назва)

на тему: Інтелектуалізована система детектування та аналізу аномалій
роботизованого палетування фармацевтичних флаконів

Виконав (-ла): студент (-ка) б курсу, групи ЛК-31мн
(шифр групи)

Згурський Данило Олегович _____
(прізвище, ім'я, по батькові)

Керівник доцент, к.т.н., доцент, Сазонов А.Ю. _____
(посада, науковий ступінь, вчене звання, прізвище, ім'я, по батькові)

Консультант _____
(назва розділу) (науковий ступінь, вчене звання, прізвище, ім'я, по батькові)

Рецензент доцент, к.т.н., доцент, Бунке О. С. _____
(посада, науковий ступінь, вчене звання, науковий ступінь, прізвище, ім'я, по батькові)

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

Київ – 2025 року

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

Інженерно-хімічний факультет

(повна назва)

Кафедра технічних та програмних засобів автоматизації

(повна назва)

Рівень вищої освіти – другий (магістерський) за освітньо-науковою програмою «Автоматизація та комп'ютерно-інтегровані технології»

Спеціальність 174 -Автоматизація , комп'ютерно-інтегровані технології та робототехніка

(код і назва)

ЗАТВЕРДЖУЮ

Завідувач кафедри

_____ Віталій ЦАПАР

(підпис)

(ініціали, прізвище)

« ____ » _____ 20__ р.

ЗАВДАННЯ

на магістерську дисертацію студенту

Згурському Данилу Олеговичу

(прізвище, ім'я, по батькові)

1. Тема дисертації Інтелектуалізована система детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів,
науковий керівник дисертації Сазонов Артем Юрійович, к.т.н., доцент,
(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом по університету від « ____ » _____ 20__ р. № _____

2. Термін подання студентом дисертації 20 травня 2025

3. Об'єкт дослідження процес роботизованого палетування

4. Предмет дослідження автоматизований пошук і аналіз аномалій в процесі роботизованого палетування фармацевтичних флаконів

5. Перелік завдань, які потрібно зробити Провести аналіз проблеми детектування аномалій процесу роботизованого палетування; визначити можливості використання штучного інтелекту в фармацевтичній промисловості для виявлення аномалій технологічних процесів; Розробити структурну схему та алгоритмічне забезпечення інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів; Підготувати набір навчальних даних

фармацевтичного виробництва для інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів; Розробити програмне забезпечення для інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів; Провести перевірку працездатності розробленої інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів.

6. Орієнтовний перелік графічного (ілюстративного)матеріалу матеріали презентації до захисту магістерської дисертації

7. Орієнтовний перелік публікацій 1. Sazonov A., Kuchkin A., Zghurskyi D. RANSAC with Sequential Probability Ratio Test as a Basis for the Unmanned Aerial Vehicle Autonomous Navigation. – Automation and Computer-Integrated Technologies – 2023. IX International Scientific and Practical Conference of Young Scientists, PhD Students and Students, ACIT – 2023 Kyiv, 19 April 2023 – Kyiv, Igor Sikorsky Kyiv Polytechnic Institute, 2021. – P. 119 – 120

2. Сазонов А.Ю., Згурський Д.О. Щодо виявлення перешкод при навігації мобільних роботів по складному рельєфу. – Комп’ютерні інтелектуальні системи та мережі – 2022. XV Всеукраїнської науково практичної WEB конференції аспірантів, студентів та молодих вчених, 22-24 березня 2022 р – Кривий Ріг, Криворізький національний університет, 2022. – с. 96 – 98

3. САЗОНОВ, А., ЗГУРСЬКИЙ, Д., & КУЧКІН, О. (2023). ВИБІР МЕТОДУ КЛАСТЕРИЗАЦІЇ ДЛЯ ЗАДАЧІ НАВІГАЦІЇ КРОКУЮЧОГО РОБОТА У НЕСТРУКТУРОВАНИХ СЕРЕДОВИЩАХ. MEASURING AND COMPUTING DEVICES IN TECHNOLOGICAL PROCESSES, 2, 34–41. <https://doi.org/10.31891/2219-9365-2023-74-5>

4. Sazonov A., Zghurskyi D., Kuchkin A. GRASPING POINTS ESTIMATION FOR ARBITRARY-SHAPED OBJECTS IN AUTOMATED PALLETIZING UNDER LOW LIGHT CONDITIONS – Automation and Computer-Integrated Technologies – 2025. XI International Scientific and Practical Conference of Young Scientists, PhD Students and Students, ACIT – 2025 Kyiv, 7 May 2025 – Kyiv, Igor Sikorsky Kyiv Polytechnic Institute, 2025. – P. 92 – 93

8. Консультанти розділів дисертації*

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

9. Дата видачі завдання 31 січня 2025

Календарний план

* Консультантом не може бути зазначено наукового керівника магістерської дисертації.

№ з/п	Назва етапів виконання магістерської дисертації	Термін виконання етапів магістерської дисертації	Примітка
1	Аналіз проблеми детектування та аналізу аномалій процесу роботизованого палетування фармацевтичних флаконів	20.02.2025	
2	Розроблення структурної схеми інтелектуалізованої системи детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів	10.03.2025	
3	Розроблення алгоритмічного забезпечення інтелектуалізованої системи детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів	25.03.2025	
4	Збирання, аннотування та аугментування навчального набору даних з процесу роботизованого палетування для навчання нейронної мережі детектування аномалій	10.04.2025	
5	Реалізація програмного забезпечення інтелектуалізованої системи детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів	20.04.2025	
6	Реалізація програмного забезпечення інтелектуалізованої системи детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів	01.05.2025	
7	Оформлення матеріалів до магістерської дисертації	13.05.2025	

Студент

(підпис)

Данило ЗГУРСЬКИЙ

(ініціали, прізвище)

Науковий керівник дисертації

(підпис)

Артем САЗОНОВ

(ініціали, прізвище)

)

Реферат

Магістерська дисертація виконана на тему: «Інтелектуалізована система детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів». В роботі наведено аналіз проблеми детектування і аналізу аномалій процесу роботизованого палетування фармацевтичних флаконів і визначення методів її вирішення. Розроблено алгоритмічне забезпечення інтелектуалізованої системи детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів, на його основі реалізоване програмне забезпечення інтелектуалізованої системи детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів. В роботі проведено збирання та модифікування тренувального та тестового наборів даних реального виробничого процесу. Наприкінці роботи проведено перевірку працездатності інтелектуалізованої системи детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів.

Програмне рішення інтелектуалізованої системи детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів впроваджене у виробничий процес.

Пояснювальна записка магістерської дисертації обсягом 81 сторінки містить 28 рисунків, 3 таблиці та 38 літературних джерел.

Ключові слова: штучний інтелект у фармацевтиці, штучні нейронні мережі, виявлення аномалій, роботизоване палетування, сегментація аномалій, інтелектуалізований аналіз аномалій.

Abstract

The master's thesis is entitled “Intelligent Anomaly Detection and Analysis System of the Pharmaceutical Vials Robotic Palletizing”. This work shows a comprehensive study of the problem of detecting and analyzing anomalies that occur during the robotic palletizing of pharmaceutical vials and identifies effective methods for its resolution. An algorithmic solution for the intelligent anomaly detection and analysis system was developed, based on which the corresponding software was implemented. The system is designed to autonomously identify deviations from the standard palletizing process using artificial neural networks and computer vision techniques. The study involved the collection and adaptation of training and testing datasets derived from real industrial processes. At the final stage, the system’s operability was validated through experimental testing under realistic production conditions.

The developed software solution has been successfully integrated into the pharmaceutical production line.

Master's thesis consists of 81 pages and contains 28 figures, 3 tables, and references to 38 sources.

Keywords: artificial intelligence in pharmacy, artificial neural networks, anomaly detection, robotic palletizing, anomaly segmentation, intelligent anomaly analysis.

ЗМІСТ

ВСТУП	14
1. Аналіз проблеми детектування аномалій в процесі роботизованого палетування фармацевтичних флаконів	16
1.1 Використання технологій штучного інтелекту в фармацевтичній промисловості.....	16
1.2 Детектування аномалій в процесі роботизованого палетування	20
1.3 Використання засобів машинного зору в промисловості для аналізу технологічних процесів шляхом детектування аномалій у зображеннях	25
1.4 Проблема детектування аномалій в процесі роботизованого палетування фармацевтичних флаконів	33
1.5 Мета та задачі дослідження	36
2. Алгоритмічне забезпечення інтелектуалізованої системи детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів ...	38
2.1 Структурна схема роботизованого палетування з інтелектуальною системою детектування та аналізу аномалій.....	38
2.2 Алгоритм детектування аномалій інтелектуалізованою системою детектування та аналізу аномалій роботизованого палетування	40
2.3 Алгоритм сегментування аномалій інтелектуалізованою системою детектування та аналізу аномалій роботизованого палетування	42
2.4 Алгоритм аналізу аномалії інтелектуалізованою системою детектування та аналізу аномалій.....	43
3. Формування навчального набору даних для інтелектуалізованої системи детектування і виявлення аномалій в процесі роботизованого палетування флаконів.....	45
3.1 Збір навчального набору даних з аномаліями.....	45
3.2 Анотування навчального набору даних.....	46
3.3 Аугментація тренувального набору зображень аномалій.....	48
4. Програмне забезпечення інтелектуалізованої системи детектування на аналізу аномалій роботизованого палетування фармацевтичних флаконів ...	51

4.1 Архітектура штучної нейронної мережі YOLOv12.....	51
4.2 Архітектура штучної нейронної мережі SAM	52
4.3 Оптимізація навчання штучної нейронної мережі	54
4.4 Навчання штучної нейронної мережі YOLOv12	57
4.5 Пошук точки затиску флакону	61
4.6 Моделювання цифрового двійника	67
5. Перевірка працездатності розробленої системи інтелектуалізованого детектування і аналізу аномалій роботизованого палетування фармацевтичних флаконів.....	72
5.1 Детектування аномалій процесу роботизованого палетування фармацевтичних флаконів.....	72
5.2 Перевірка працездатності модуля інтелектуалізованого аналізу аномалій процесу роботизованого палетування фармацевтичних флаконів..	75
ВИСНОВКИ.....	80
Список використаних джерел	81
Додаток А. Довідка про впровадження результатів роботи.....	86

ВСТУП

Технології штучного інтелекту з кожним днем все більше витісняють традиційні методи в технологічних процесах промислового виробництва. Фармацевтичне виробництво не є виключенням. Буквально на кожному етапі від концепту до фінальної продукції використовуються новітні технології з використанням штучних нейронних мереж для аналізу надзвичайно великих обсягів даних та передбачення впливу великої кількості факторів.

Сфера виявлення і аналізу аномалій в режимі реального часу у ході технологічного процесу є надзвичайно важливою, оскільки виробництво ліків кожного дня вдосконалюється і потребує нових рішень і своєчасних реагувань на аномалії, що можуть привести до не бажаних наслідків. Процес палетування, зазвичай, є майже кінцевим етапом виробництва продукту, це означає що ризик виникнення барку мають бути найменший, оскільки на ньому відбувається робота над фармацевтичною речовиною в певній герметичній ємності.

Виконання ручної корекції аномалій в автоматизованому процесі роботизованого палетування крім затримок на невизначений період часу, можуть нанести критичний вплив на хід виконання автоматичної операції, що підтверджує **актуальність теми**.

Метою роботи є підвищення продуктивності технологічного процесу роботизованого палетування та рівня захисту людини на фармацевтичному виробництві шляхом впровадження інтелектуалізованого модуля детектування і аналізу аномалій.

Для досягнення поставленої мети необхідно розв'язати наступні **завдання**:

- 1) Провести аналіз проблеми детектування аномалій процесу роботизованого палетування; визначити можливості використання штучного інтелекту в фармацевтичній промисловості для виявлення аномалій технологічних процесів;

- 2) Розробити структурну схему та алгоритмічне забезпечення інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів
- 3) Підготувати набір навчальних даних з фармацевтичного виробництва для інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів
- 4) Розробити програмне забезпечення для інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів
- 5) Провести перевірку працездатності розробленої інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів

Об'єктом дослідження є процес роботизованого палетування.

Предметом дослідження є автоматизований пошук і аналіз аномалій процесу роботизованого палетування фармацевтичних флаконів.

1. АНАЛІЗ ПРОБЛЕМИ ДЕТЕКТУВАННЯ АНОМАЛІЙ В ПРОЦЕСІ РОБОТИЗОВАНОГО ПАЛЕТУВАННЯ ФАРМАЦЕВТИЧНИХ ФЛАКОНІВ

1.1 Використання технологій штучного інтелекту в фармацевтичній промисловості

Впровадження штучного інтелекту (ШІ) у виробництво лікарських засобів спрямоване на підвищення ефективності контролю процесів та оптимізацію технологічних операцій. Використання новітніх алгоритмів порівняння даних надає можливість інтегрувати інформацію з величезної кількості різних джерел, наприклад, числові ряди можуть забезпечити комплексний аналіз якості виробленої продукції. На ряду з цим використання методів зниження розмірності, такі як t-розподілене вкладання стохастичної близькості (t-SNE – t-distributed Stochastic Neighbor Embedding) або прихований розподіл Дирихле (LDA – Latent Dirichlet Allocation), дозволяють спростити великий обсяг даних і без втрат основних закономірностей значно підвищити ефективність управління процесом.

Введення в фармацевтичне виробництво таких методів, як регресійний аналіз та вимірний аналіз, зокрема аналіз головних компонент (PCA – Principal Component Analysis) та метод часткових найменших квадратів (PLS – Partial Least Square), надало можливість виявляти приховані взаємозв'язки з подальшим зменшенням кількості контрольованих параметрів, що призвело до зниження складності виробництва. Баєсівські мережі та жадібний пошук еквівалентних структур (GES – Greedy Equivalence Search) стали одними із найбільш вживаних алгоритмів виявлення причинно-наслідкових зв'язків і дозволили ідентифікувати основні фактори впливу та їх взаємодію без попереднього задання структури моделі.

Імплементація методів кластеризації та розпізнавання шаблонів на базі методу опорних векторів і k-середніх вплинуло на швидке виявлення повторюваних поведінкових структур. Таке явище стало важливим у

виявленні потенційних дефектів і позитивних тенденцій упродовж всього виробничого циклу. Використання прогностичних моделей на базі штучних нейронних мереж (ШНМ) та варіацій алгоритму випадкового лісу забезпечили можливість оперативного прогнозування параметрів виробництва та своєчасного реагування на потенційні відхилення в технологічному процесі.

Під час виробництва активних фармацевтичних інгредієнтів (АФІ) ретельно контролюється стабільність фізико-хімічних властивостей і точність дозування. Застосування методів на базі ШІ дозволяє досягати високої консистентності партій з забезпеченням відповідності встановленим стандартам якості. Машинне навчання відкрило шлях до ефективного аналізу історичних даних, що сприяло оптимізації процесів та швидкому виявленню потенційних відхилень, що можуть вплинути на якість продукту.

Зазвичай фармацевтичне виробництво використовує два основних підходи до виробництва лікарських засобів: партійний та безперервний.

Партійний процес виробництва являє собою послідовність певних операційних етапів, розміщення яких можливе на різних виробничих майданчиках, а час виробництва може сягати місяців. Характерною особливістю такого виробництва є наявність періоду утримання після кожного з етапів. Такі періоди необхідні для проведення оцінки зразків на відповідність якості за валідаційними протоколами. Процедура оцінки якості зазвичай є складною та витратною за часом, бо містить суттєві перерви між етапами процесу. Усе це на ряду з зберіганням і транспортуванням до інших об'єктів створює ризики до якості АФІ, які можуть деградувати під впливом навколишнього середовища.

Впровадження технологій ШІ на окремих етапах виробництва вже приносить користь процесу партійного виробництва лікарських засобів. Наразі відбувається використання ШІ із людським наглядом, що у партійному виробництві призвело до зменшення кількості помилок і встановило високий рівень стандартизації. Подальший розвиток інтеграції у фармацевтичну галузь має надати можливість краще відповідати вимогам постачання:

- Скорочення періоду утримання між етапами виробництва;
- Зменшення помилок від «людського фактору»;
- Спрощення ведення валідаційної документації;
- Збільшення операційної гнучкості на час транспортування і зберігання.

В свою чергу, безперервний метод орієнтований на постійний виробничий процес і складається з короткого ланцюга постачання. При цьому контроль якості здійснюється в режимі реального часу на кожному з усіх послідовних етапів. Під час безперервного виробництва ІІІ дозволяє точно регулювати параметри процесу, детально контролювати роботу обладнання за допомогою аналізу даних з сенсорів та візуального моніторингу. Така інтеграція допомогла досягти своєчасне виявлення відхилень від встановлених стандартів, наприклад знаходження потенційних джерел забруднення. Це стало основою для подальшої трансформації безперервного процесу виробництва та переходу до більш ефективних, масштабованих і економічно вигідних виробничих технологій [1].

Одним з таких виробничих етапів є палетування, який у той же час є одним з перших процесів, який отримав вигоду від інтеграції ІІІ та впровадження індустріальної роботизації. Використання роботизованого маніпулятора (Articulated robot) виявило себе надзвичайно ефективним для роботи на виробничу лінію процесу через свою ефективність. Такі роботи можуть обслуговувати одразу декілька виробничих ліній і взаємодіяти з середовищем підприємства.

В цілому, програма робота концентрує увагу на трьох основних проблемах, оптимізацією яких займаються дослідники протягом десятиліть:

- планування задачі – послідовність дій задля забезпечення успішного виконання операції, яке досягти індивідуальною дією неможливо;
- розподіл часу – кожна окрема задача із загального набору поставлених задач має бути задано послідовно з визначеним часом виконання дії;

- планування руху – переміщення із однієї точки в іншу без перетину з перешкодами.

Програма процесу палетування є «pick-and-place» концептом і складається з певної послідовності дій: взяти об'єкт з виробничої лінії, перенести його до кінцевої позиції, визначити належний кут, поставити об'єкт на палету. Така програма оперує за наперед визначеною послідовністю рухів, які активуються за зовнішнім сигналом (тригером) від оптичного датчику, який визначає наявність і положення об'єктів на конвеєрі [2].

В фармакологічному виробництві інфузійних розчинів, об'єктом є наповнені рідиною флакони. При чому характерним є наявність одразу двох процесів палетування: передстерилізаційний, призначений для жорстко фіксованого компонування щойно наповнених флаконів по металевих лотках задля подальшої їх стерилізації; та пакувальний, кінцевий процес фасування флаконів в коробки та на палети.

Також, надзвичайно критичним у фармацевтичному виробництві є дотримання строгих вимог, таким як дотримання GMP (Good Manufacturing Practice), міжнародних галузевих стандарти ISO та міжнародних рекомендацій ICH Q6, тощо. Часте виникнення аномалій можуть привести до значних затримок, які призведуть до порушення технологічного процесу виробництва і призведе до зіпсування рідини, що зробить продукт непридатним для використання та вимагатиме його утилізації.

Таким чином, використання технологій ІІІ виявилось особливо ефективним як під час розробки так і під час вдосконалення лікарських засобів. Інтеграція новітніх технологій до виробничих етапів, наприклад, палетування флаконів роботизованою лінією може надати можливість підвищити контроль та якість виконання процесу без втручання оператора, зменшити ризики пошкодження АФІ.

1.2 Детектування аномалій в процесі роботизованого палетування

Роботизоване палетування – один з проявів загального процесу автоматизації внутрішньої логістики з використанням рішень робототехніки. Сфера робототехніки називається відповідно до автоматизованого об'єкту – логістична робототехніка, що має на меті автоматизувати матеріальні потоки на логістичних станціях виробництва.

Однак, оточення логістичного робота зазвичай динамічне і має в собі гнучкі елементи, як наприклад контейнер. Оточуюче середовище змінюється протягом всього виконання роботом завдання і пов'язаних з ним маніпуляцій. Основуючись на взаємозв'язку «робот-об'єкт» можна поділити сприйняття робочого середовища роботом на: процес захоплення та процес після захоплення, які наведено на рис. 1.1.




Рисунок 1.1 – Розподіл процесів маніпуляцій робота над об'єктом під час етапу палетування, запропонований Ф. Куреком[3]

Етап захоплення складається з послідовного виконання дій роботизованої системи: виявлення і планування взяття об'єкту. Коли об'єкт захоплено, на підставі аналізу робочого середовища, відбувається виконання необхідних маніпуляцій над ним і його транспортування до прогнозованого місця на палеті. Після цього, робот розділяється з об'єктом шляхом виконання дій розміщення. Надалі правильність отриманого результату ітерації програми робота перевіряється певним модулем контролю результатів дій робота.

Детектування аномалій – інструмент контролю робочого оточення і перевірки результатів виконання дій для робота. Завдання інтелектуалізованого модуля детектувати відхилення в процесі розміщення об'єкта на палеті.

Проблема детектування аномалій посиляється на пошук шаблонів в інформації, яка не схожа на очікувану поведінку і вимагає тільки дані з системи, що працює в нормальному стані. Такий підхід дозволяє використовувати методи навчання під наглядом. На роботі-маніпуляторі з 6 ступенями свободи можливе використання набору датчиків, які дозволяють вимірювати конфігурацію ланок робота, швидкості ланок, напругу на сервоприводі ланки і 6-вимірна сила-крутний момент в точці центру інструмента (TCP – Tool Center point).

Використовуючи такий набір даних, автори дослідження [4] інтегрували декілька типів методів виявлення аномалій. Одним з таких типів були методи на основі примірників: методи, які виявляють аномалію оцінюючи відстань між збереженими та запитуваними даними. Коли аномальний примірник має значну відстань до своїх сусідів ніж нормальний, тоді він класифікується як викид. Такими методами слугують k-найближчих сусідів (kNN – k-Nearest Neighbors) та локальний фактор викиду (LOF – Local Outlier Factor). При використанні k-вимірних індексних дерев можливо знизити їх обчислювальну складність з $O(N)$ до $O(\log N)$, де N – кількість тренувальних примірників.

Іншим типом є моделі явного узагальнення. Використання методів PCA та його варіацій може бути як окремим методом детектування аномалій так і кроком виявлення ознак з набору даних для іншого метода. PCA використовується для проєкції даних у простір меншої розмірності, де проводить реконструкцію та обчислює помилку такої реконструкції. Імовірнісний PCA (PPCA – Probabilistic PCA) замість відстані посиляє вірогідність належності даних до моделі. Інкрементний PCA (IPCA – Incremental PCA) займає менше пам'яті, оскільки тренується послідовно невеликими наборами даних. Також дослідники реалізували One-Class Support

Vector Machine (OCVM) у поєднанні з IPCA, що мала обчислювальну складність $O(N^2)$.

Наступними методами виявлення аномалій є використання автоенкодерів (AE – Autoencoder). Структура і принцип роботи AE наведені в наступному пункті розділу. Для виявлення аномалії можливе використання різних модифікацій AE, деякі з них:

- Undercomplete AE – AE зі звуженою архітектурою і середньоквадратичною помилкою як функція втрат;
- Denoising AE – AE до вхідних даних якого додається шум;
- RandNet – ансамблевий AE в з випадковим розривом зв'язків між шарами;
- Variational AE – містить імовірнісний прихований простір з використанням KL-дивергенції;
- Long Short-Term Memory AE – мережа використана для часових рядів;
- Bilinear AE – AE з білінійним перетворенням для стискання просторово-часових залежностей.

Такі методи гарні у використанні аномалій рухів робота, наприклад при раптовій зміні переносній ваги, зіткнень з перешкодами, затримці у програмі або зміні параметрів рухів робота. Тобто вони охоплюють процес взяття і маніпулювання з об'єктом, але їх не можна використати для швидкого реагування на виникнення аномалії після розміщення об'єкту на палеті.

Виявлення аномалій у рухах робота, але за умов використання менш ресурсозатратних датчиків і можливістю до впровадження до будь-якого промислового робота, без втручання у середину механізму, запропонували автори у дослідженні [5]. Стаття призначена розробці глибокої мережі переконань (DBN – Deep Belief Network) з трьома послідовними етапами: отримання вібраційних сигналів кожної ланки робота; побудова векторів

енергетичної ентропії і послідовне шарове навчання DBN зі зворотнім тонким налаштуванням.

Вони домоглися точності виявлення як однієї несправності, 99,4%, так і декількох одразу, 85% – при п'яти несправностях. Такий метод підходить до використання у реальному виробництві, а також додатково може виявляти стан робота і попередньо упереджати про необхідність сервісного обслуговування в системах з будь-яким промисловим роботом.

Схожих результатів опублікували дослідники у [6], де запропонували виявлення аномалій рухів маніпуляційних промислових роботів шляхом аналізу відеопотоку даних в реальній часі без використання датчиків або втручання до внутрішньої системи управління. Вони висвітили проблеми дорогої вартості обладнання, високої залежності від датчиків, відсутності універсального протоколу зв'язку комплексу обладнання від різних виробників і необхідність втручання у системи моніторингу та виконання.

Ними було запропоновано підхід візуального аналізу рухів робота з використанням сегментації зображення роботу на кожному кадрі за допомогою HSV-моделі. Кожне положення робота кодується у вигляді хешу, після чого будується послідовність нормальних рухів. У разі виявлення відхилення від норми виконання робочої програми робота аварійно завершується.

Така система змогла досягти високих показників (99,15%) точності виявлення аномалій руху з середнім часом обробки кадру 0,073с при фіксованих інтервалах. Однак, існують великі обмеження щодо фонового середовища і, така система виявляє лише аномалії руху робота, а технологічної операції, яку він виконує.

Найбільшої застосовності вирішення задач пошуку аномалій як у процесі так і після розміщення об'єкту на палеті набуло використання систем комп'ютерного зору: візуальне визначення наявності аномалій за допомогою камер і певного модулю аналізу зображення, наприклад, моделі глибинного навчання.

Використання систем машинного зору в промисловості є надзвичайно важливим аспектом виробничого циклу, оскільки вони надають змогу перевіряти хід виконання технологічного процесу, якість продукції продукції на всіх етапах виробництва. Традиційно, аномалії виявлялись ручною інспекцією, що ґрунтувались на судженні людини. Однак такий підхід є надзвичайно часозатратним і не враховує різноманітність суджень операторів, які впливають на їх сприйняття аномалій.

Наразі існують велика кількість викликів як наукових, так і промислових, для використання систем промислового виявлення аномалій. Першим з яких є використання технологій в реальному часу. Система повинна працювати з низькою затримкою, що робить класичні високоточні офлайн-підходи не ефективними і виникає велика потреба у легковагових моделей з граничним обчисленням.

Складність та текстура дефектів є наступним викликом, оскільки в реальному світі є надзвичайно велика різноманітність розмірів, кольорів, форм аномалій і дефектів, які не тільки можуть бути на складному фоні, так і в комбінації один з одним одночасно. Ця проблема спонукає поєднувати джерела інформації, наприклад додавання даних про глибину чи інфрачервоних знімків.

Іншою важливою проблемою є малорозмірні аномалії і складність їх анотації. Якщо розмір аномалії стає несприйнятним людським оком, але вони є критичними то виникає потреба не тільки їх виявити, але нанести розмітку враховуючи інформацію кожного пікселя аномалії і зони біля неї. На сьогоднішній день, рішенням може бути синтетична анотація даних з використанням генеративних моделей.

Незбалансованість і неадекватність набору даних промислових аномалій зазвичай містять у собі надмірну кількість без аномальних знімків, що призводить до перенавчання моделі. Проблеми з шумом та освітленням промислового середовища зазвичай додають складності моделям пошуку аномалій. Такі обставини вимагають синтетично генерувати дані,

застосовувати велику кількість аугментацій для універсальності моделі. Іноді з цією проблемою може справитись навчання моделі з невеликою кількістю даних – few-shot навчання.

Останнім викликом є інтеграція в промисловість, оскільки це потребує інвестицій і оновлення застарілої інфраструктури. Перехід до сучасних протоколів в промислових налаштуваннях і обмін даними між машинами необхідний, що закладається в основу побудови сучасних промислових систем [7].

Одним з перспективних напрямків вирішення цих проблем є інтеграція пояснювального ШІ (XAI – Explainable Artificial Intelligence), бо наразі надзвичайно складно виявити весь шлях прийняття рішення у виявленні аномалій всередині навчених моделей. XAI зможуть надати інформацію, наприклад, чому деякі аномалії мають більшу точність виявлення за інші та які особливості є ключовими в їх пошуку [8].

Поєднання текстової інформації з візуальною може створити надзвичайно потужний інструмент промислового детектування аномалій – LVLMS (Large Vision-Language Models). Такі моделі засновані на великих мовних моделях (LLM – Large Language Models), але їх процес міркування включає у себе як зображення, так і текст, а функція втрат має бути ефективна з цими типами даних [9].

Отже, ШІ в фармацевтичному виробництві виступає надзвичайно потужним засобом оптимізації процесів і забезпечення якості. Через наявну здатність до імітації процесів людського навчання, мислення та самокорекції, ШІ гарно проявляє себе у таких задачах як управління виробництвом, прогнозування та детектування аномалій, оптимізації ланцюгів постачань.

1.3 Використання засобів машинного зору в промисловості для аналізу технологічних процесів шляхом детектування аномалій у зображеннях

Детектування аномалій технологічного процесу або готової продукції, шляхом аналізу зображень є актуальною задачею у багатьох галузях. Одним з підходів до розв'язання цієї задачі є використання АЕ. Структура простого АЕ наведена на рис.1.2.




Рисунок 1.2 – Типова структура АЕ для детектування аномалій

АЕ ґрунтується на принципі відтворення вхідного сигналу через стиснення інформації у прихованому просторі. Під час реконструкції сигналу можливо використовувати величину реконструкційної помилки як індикатор аномалії. Для роботи з зображеннями зазвичай використовують згорткові автоенкодери, з використанням згорткових шарів для прийняття просторової структури зображень, іноді застосовують варіаційні АЕ з прихованим розподіленням [10].

У статті [11] представлена модифікований підхід виявлення аномалій – використання спільного АЕ з структурою енкодер-декодер-енкодер. Розробивши двофазний режим навчання: базовий та протидіючий, коли одна структура мінімізує різницю між вхідними і вихідними даними, а інша

максимізує, автори досягли підвищеної точності. На типових наборах даних було показано потенційність застосувань інтеграції спільного АЕ та процедури протидії між компонентами ШНМ у галузі машинного зору.

Додатково, в умовах Індустрії 4.0, глибокі АЕ показали ефективність детектування аномалій у багатовимірних часових рядах на базі згорткових шарів досягнувши точності 94% [12].

Іншим напрямком виявлення аномалій є застосування генеративно-змагальних мереж (GAN – Generative Adversarial Network). В основі лежить генератор, який створює зображення, схожі до нормальних, та дискримінатор, який вчиться відрізняти справжні зразки від штучно створених. Структура GAN для аналізу зображень наведена на рис.1.3.




Рисунок 1.3 – Типова архітектура мережі GAN для детектування аномалій

Дослідники у статті [13] використали U-подібний генератор, де згорткові блоки замінили на механізм self-attention та використали модифікації skip-connection, що дозволило поєднувати глобальну інформацію з

локальними деталями при навчанні. Також, авторами було запроваджено адверсальну функцію витрат. Практичні результати демонструють перевагу над традиційними згортковими підходами і розширюють можливості автоматизованої діагностики.

У праці [14] проведено аналіз потенційних шляхів вдосконалення методів застосування GAN і показано їх актуальність застосування як складової систем машинного зору в сфері інспекції виробничого контролю і сумісних до неї, в задачах зображувальної інтерпретації, сегментації та генерації даних.

Найбільш популярним методом виявлення аномалій в системах машинного зору є використання згорткових ШНМ (CNN – Convolutional Neural Network). Такі архітектури надзвичайно гарно виділяють ознаки зображення, які потім використовуються для класифікації зображень, виявлення об'єктів, сегментації зображень й інших задач. Типова архітектура CNN наведена на рис.1.4.




Рисунок 1.4 – Типова архітектура CNN для детектування аномалій

Автори у статті [15] запропонували автоматизований підхід для аналізу поверхневих об'єктів на використанні CNN з триплетним навчанням. Така методологія може стати універсальною системою виявлення аномалій для високоточних аналіз текстурних характеристик в різних галузях промисловості для забезпечення якості вихідної продукції.

Дослідники [16] розробили систему моніторингу зносу інструментів в умовах реального виробництва, використовуючи алгоритми глибокого навчання. Отримані результати мають вагомий вагомий результати у галузі машинобудування. У той же час в роботі [17] запропонували інтегровану

систему для автоматизованого виявлення і сегментації дефектів виробництва, на системі трансферного навчання.

Сучасні методи виявлення об'єктів у зображенні за структурою зазвичай поділяють на двостадійні і одностадійні. До першої групи належить Faster R-CNN, до другої – SSD, RetinaNet і різні варіації YOLO.

ШНМ Faster R-CNN являє собою двостадійну обробку: спочатку Region Proposition Network (RPN) на основі ResNet або VGG 16, генерує певну кількість якісних кандидатів, потім інший модуль визначає їх межі і класи. Введення RPN зробило процес диференційованим і прибрало методику вибіркового пошуку, але це значно знизило швидкість, приблизно 5 кадрів на секунду при високій точності на наборі даних COCO. Введення піраміди ознак (FPN – Feature Pyramid Network) значно поліпшило можливість ШНМ локалізувати дрібні об'єкти, які до цього були слабкістю двостадійних схем.

Два основних недоліки Faster R-CNN намагались усунути дослідники у статті [18]: чутливість до дрібних, прихованих об'єктів на знімках; та зависоку часту хибних прив'язок через якорі прямокутної форми у випадку роботи з круглими об'єктами. Першою ключовою зміною була обмеженість простору пошуку RPN за кольоровими ознаками та впровадження округлих еталонів різного діаметру як якорів. Другою – адаптація гілки регресії для виявлення еліптичних ознак, що підвищило точність центрування і зменшило площу зайвого фону.

SSD ґрунтується на класичному згортковому екстракторі ознак – спершу це була VGG 16, надалі ResNet, після чого мапи ознак різних масштабів генерують обмежувальні рамки та їх класи. Оскільки SSD була однією з перших моделей, у якої відмовились від використання окремого блоку пропозицій регіонів, вона змогла забезпечити швидкість 59 кадрів за секунду. Під час навчання моделі застосовується жорстке відбирання негативних прикладів, через що SSD не засвоює перевагу фону над корисними даними.

Хоча модель в оригінальному вигляді вже не має переваг над сучасними згортковими ШНМ, її модифікації знаходять практичні застосування.

Наприклад, у праці [19] дослідники створили Enhanced SSD (ESSD), замінивши VGG 16 на CSP подібний каркас, що збільшило кількість багатомасштабних мап ознак. Також, до ESSD інтегровано сучасні функції активації та втрати з методом просторової уваги. Експериментальні результати показали гарний баланс між точністю і обчислювальною вартістю з перевагою над базовою моделлю, але при тому, з меншими показниками точності ніж у YOLOv7 та YOLOv8.

У статті [20] було запропоновано удосконалений алгоритм детектування об'єктів на аерофотознімках Feature Enhancement SSD. Практичні результати з впровадження цілеспрямованого збагачення ознак і використання уваги в межах одностадійної структури дало змогу поєднати високу швидкодію з точністю, яка схожа з двокадровими системами. Авторам вдалося підвищити загальну точність локалізації ШНМ з 77,5% до 89,1%, а хибні і пропущені детектування знизились майже на половину – з 26,2% до 14,7%.

Особливістю RetinaNet було впровадження поєднання швидкості одностадійних підходів з точністю двостадійних. Архітектура базується на ResNet з FPN, проте у ній запроваджено фокальну функцію втрат, яка дозволила зменшити внесок легких, фонових прикладів і сконцентрувати увагу НМ на рідкісних важких випадках. Перша версія НМ змогла досягти швидкості 12 кадрів на секунду при точності рівній двостадійній архітектурі Faster R-CNN.

Однією з найбільш популярних структур НМ, що постійно вдосконалюється є модель «You Only Look Once» – YOLO. Розвиток сімейства YOLO є яскравим прикладом послідовності поліпшення використання технологій згорткових ШНМ:

- Перший YOLO почав обробляти знімки єдиною згортковою ШНМ і одразу створювати координати рамок і ймовірності класів. Задача виявлення об'єктів стала регресійною і виконувала локалізацію та класифікацію за один такт;

- Другий YOLO9000 впровадив багатооб'ємне навчання і кластери розмірів прив'язок, що адаптувались до статистики об'єктів у даних;
- У третій YOLOv3 автори розробили трирівневу детекцію на основі Darknet-53 із залишковими зв'язками і технологію Spatial Pyramid Pooling чим покращили точність виявлення дрібних і великих класів;
- Четверта ітерація використовувала CSPDarknet-53 із Mish функцією активації, до того ж з'явились «bag-of-freebies» прийоми, такі як мозаїчна аугментація чи CIOU-втрата;
- YOLOv5 було переведено на PyTorch, у якій спростили конфігурацію і додали модуль PANet із багатовекторним злиттям ознак і методикою anchor-free. Модель стало легше розгортати і простіше навчати;
- У YOLOv6 було приділено увагу промисловому використанню: інтеграція механізму self-attention, відмова від фіксованих якорів, що зменшило кількість гіперпараметрів;
- YOLOv7 вперше інтегрувала трансформерні механізми в одностадійну детекцію і запровадила блок повторної параметризації E-ELAN;
- У YOLOv8 було застосовано генеративні аугментації і розширено функціональність до сегментації, паноптичної розмітки і оцінки поз;
- НМ YOLOv9 ввела концепцію Programmable Gradient Information і архітектуру GELAN, що дозволило вибірково посилювати потрібні градієнти і стабілізувати процес навчання;
- У YOLOv10 розробники відмовились від некорелюючої фільтрації, притаманній більшості НМ, чим зменшили затримку;
- YOLOv11 розвинула ідею компактності пришвидшивши CSP-перетворення, додавши механізм просторової уваги, що

підвищило показники точності і зменшило гіперпараметри на чверть порівняно з восьмою версією. Крім виявлення об'єктів, моделі уніфіковано до сегментації, виявлення поз та обертальних рамок, при цьому модель поділена на лінійку від nano до xlarge задля використання на різних обчислювальних потужностях [21].

Автори статті [22] на наборі медичних зображень з 52 тисячами зображень співвідношення швидкості і точності SSD, RetinaNet, YOLOv3. За підсумками тестування RetinaNet продемонструвала показник загальної точності по всіх класах 82,89% і 17 кадрів на секунду, SSD надала 82,71% при швидкості 32 кадри на секунду, YOLOv3 – 79% при швидкодії 69 кадрів на секунду. НМ сімейства YOLO мала найбільшу швидкодію, компактність і надає конкурентну точність відносно інших мереж.

Для автоматичного аналізу об'єктів на знімках зазвичай не достатньо просто визначити його наявність, а необхідно ще сегментувати його, прибравши зайву інформацію, пікселі, на зображенні. В залежності від масштабу об'єкту аналізу сегментація поділяється на семантичну сегментацію та сегментацію примірників.

За умови необхідності аналізу класів об'єктів, наприклад, в контексті палетування, виокремлення флаконів від лотка, використовуються методи і моделі семантичної сегментації. Кожний піксель знімку буде призначений заданим класам об'єктів. Такий вид сегментації надзвичайно поширений в роботах пов'язаних з мапами та аналізом поверхні Землі.

В задачах, де необхідно дослідити конкретний екземпляр класу, наприклад впалий флакон для визначення точки захвату, використовують моделі сегментації примірників. Результатом роботи таких моделей буде поділ всіх пікселів зображення на окремі індивідуальні об'єкти, що дозволить детально виявити і проаналізувати бажаний екземпляр класу [23].

Використання згорткових ШНМ для задачі виявлення детектування аномалій та визначення точки захвату є доцільним, оскільки CNN добре справляються із вилученням локальних ознак зображення. Саме завдяки своїй

здатності автоматично виділяти характерні риси об'єктів у зображеннях, CNN дозволяють ефективно локалізувати флакон навіть у складних умовах фонового шуму або коли об'єкт має неочевидну орієнтацію. Після попереднього виявлення об'єкта за допомогою CNN можна застосувати додаткові модулі, які виконують регресію чи оцінку ключових точок для визначення оптимальної точки захвату.

1.4 Проблема детектування аномалій в процесі роботизованого палетування фармацевтичних флаконів

Автоматизований процес роботизованого палетування зазвичай відбувається в умовах постійних вібрацій та коливань, спричинених рухом виробничих ліній і механічною взаємодією робота з вантажем. Такі збурення іноді призводять до появи аномалій, які порушують стандартизовану послідовність укладання флаконів. В процесі палетування фармакологічних флаконів однією з найпоширеніших аномалій є флакон, що впав. Ця аномалія руйнує однорідність рядів флаконів, оскільки він порушує рядність і фіксованість флаконів, а також унеможлиблює подальше безпечне вкладання формування штабелів і збільшує ризик пошкодження наступних одиниць продукції. На рис.1.5. наведено типову аномалію – флакон, що впав у лотку.




Рисунок 1.5 – Аномалія процесу роботизованого палетування фармацевтичних флаконів

Поява такої аномалії призводить до зупинки лінії для ручного втручання і корекції. Крім того, неверифікована орієнтація флакона ускладнює виконання повторного захвату автоматичним маніпулятором.

Причиною виникнення аномалії можуть бути багато факторів, основні з яких:

- відхилення вхідної речовини, що формує тіло флакону і призводить до зміни властивостей щільності, ковзання та форми флакону в цілому. Зміни властивості ковзання можуть проявлятися через проходження через зони очищення, що змінює коефіцієнт тертя між флаконом і поверхнею лотка;

- деформація самої палети, наприклад, дно металевого лотка, який піддається довготривалому навантаженню високими температурами та постійною вагою. Поступове прогинання дна формує нерівні поверхні, що сприяє незбалансованому розміщенню флаконів. ;

- дефектна одиниця продукту, яка навіть при наявності попереднього етапу інспекції якості перед палетуванням може потрапити на виробничу лінію. Нерівномірна шия флакона, неякісне ущільнення кришки, вм'ятини призводять до накопичення ймовірності виникнення аномалії у зоні палетування.

У поточних умовах контроль виконання процесу роботизованого палетування здійснює оператор лінії. Виявлення і виправлення аномалії потребує втручання оператора в процес, що призводить до зупинки виробничої лінії, ручної корекції аномалії та поновлення роботи лінії. Ці дії призводять до втрати часу, що в свою чергу перетворюється в затримки виробництва й фінансові втрати.

Окремим ризиком є взаємодія оператора з лінією роботизованого палетування: виникнення аномалії може спричинити падіння флакону на будь-якій секції лотка під стельовим роботом, що може вимагати від виробника фізичного доступу до вузьких і потенційно небезпечних зон з різних сторін роботизованої платформи. Це створює підвищений ризик травматизму.

Для реалізації автоматичної корекції аномалії необхідно детектувати аномалію та передати коригуючому модулю, що керує відповідним захватом робота, дані для усунення аномалії. Такі дані повинні надати повну інформацію про спосіб взяття флакону, тобто зорієнтувати захват робота таким чином, щоби вектори орієнтації захвата і флакона були синхронізованими, оскільки точка траєкторії робота являє собою комбінацію просторових координат і векторів. Точки захоплення флакону та координат захвату ТСР робота наведено на рис 1.6.




Рис. 1.6 – Схематичне зображення аномалії, точки захоплення флакону і захвату робота, де $C_{VI} = \{x, y, z\}$ – координати точки захвату на флаконі, P_{Gr} – точка координат захвату робота, O_{Gr} – орієнтація захвату робота

Таким чином, вирішення проблеми детектування аномалій є ключовим кроком для підвищення продуктивності виробництва та безпеки праці. Автоматизація детектування і аналізу аномалій знижує час простою лінії, мінімізує ризик травматизму персоналу і забезпечує стабільність фармацевтичного середовища відповідно до вимог галузевих стандартів.

1.5 Мета та задачі дослідження

В зв'язку з цим метою роботи є підвищення продуктивності, поліпшення рівня захисту людини на фармацевтичному виробництві процесу роботизованого палетування шляхом впровадження інтелектуалізованого модуля детектування і аналізу аномалій.

Для досягнення мети необхідно розв'язати наступні задачі:

- 1) Провести аналіз проблеми виникнення аномалій процесу роботизованного палетування; визначити можливості використання штучного інтелекту в фармацевтичній промисловості для виявлення аномалій технологічних процесів;
- 2) Розробити структурну схему та алгоритмічне забезпечення інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованного палетування фармацевтичних флаконів
- 3) Підготувати набір навчальних даних фармацевтичного виробництва для інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованного палетування фармацевтичних флаконів
- 4) Розробити програмне забезпечення для інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованного палетування фармацевтичних флаконів
- 5) Провести перевірку працездатності розробленої інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованного палетування фармацевтичних флаконів

2. АЛГОРИТМІЧНЕ ЗАБЕЗПЕЧЕННЯ ІНТЕЛЕКТУАЛІЗОВАНОЇ СИСТЕМИ ДЕТЕКТУВАННЯ ТА АНАЛІЗУ АНОМАЛІЙ РОБОТИЗОВАНОГО ПАЛЕТУВАННЯ ФАРМАЦЕВТИЧНИХ ФЛАКОНІВ

2.1 Структурна схема роботизованого палетування з інтелектуальною системою детектування та аналізу аномалій

Загальна структурна схема системи роботизованого палетування з інтелектуалізованим модулем виявлення аномалій наведена на рис.2.1. Система має реагувати на виникнення аномалій, детектувати та аналізувати їх і надавати коригуючі дані до логістичних робіт задля автоматичної корекції.




Рисунок 2.1 –Структурна схема роботизованого палетування з інтелектуальною системою детектування та аналізу аномалій, де $V_i | i = \overline{1, I}$ – i -й флакон, f – збурення, Im – поточне зображення, Im_{vi} – виявлена аномалія процесу палетування, Im_{norm} – нормальне

зображення, $e = Im_{Vi} - Im_{norm}$ – похибка керування, $C_{VI} = \{x, y, z\}$ – координати точки захвату, $O_{VI} = \{V_x, V_y, V_z\}$ – вектор орієнтації флакону, $PO_{VI} = f(O_{VI}, C_{VI})$ – параметри корекції

Певний транспортний механізм, конвеєр, безперервно підводить флакони V_i до робочої зони роботизованого палетування. Такий потік нормально орієнтованих флаконів надходить до модулю роботизованого палетування. На цьому модулі робот, 6-осьовий маніпулятор, розташовує групи флаконів у секції палети за заданою технологічним процесом схемою. На цьому етапі можлива поява збурень f , такі як зміщення, перекидання чи відсутність флакона.

Після кожного робочого циклу робота виконується передача поточного зображення Im від камери до системи детектування аномалій. Така система базується на алгоритмах машинного зору і виконує операцію детектування аномалій, після чого передає аномалію Im_{Vi} до компаратора. Компаратор обраховує похибку керування e за порівнянням зображення від системи детектування аномалій з нормальним зображенням. Після обчислення мапи різниць, у випадку наявного перевищення порогових значень формує на виході сигнал наявності аномалії і надсилає її бінарне зображення.

Система інтелектуалізованого аналізу аномалій приймає на вхід бінарне зображення та поглиблено оброблює його. Після чого обчислює точку захоплення C_{VI} , вектор орієнтації флакона O_{VI} . Результат система передає на блок роботизованої корекції.

Модуль роботизованої корекції прораховує кінематичні параметри корекції аномалії PO_{VI} , після чого надає їх модулю роботизованого палетування, де другий маніпулятор або додаткова кінематична група основного робота отримує параметри корекції і виконує маніпуляції над флаконами задля усунення аномалії.

2.2 Алгоритм детектування аномалій інтелектуалізованою системою детектування та аналізу аномалій роботизованого палетування

Система детектування аномалій складається з двох процесів: виявлення аномалії на зображенні і сегментації аномалії для подальшого обрахунку геометричних параметрів для корекції. Алгоритм виявлення аномалії наведено на рис.2.2.




Рисунок 2.2 – Алгоритм детектування аномалій інтелектуалізованою системою детектування та аналізу аномалій процесу роботизованого палетування фармацевтичних флаконів

Даний алгоритм призначений для виявлення аномалії в режимі реального часу та попередньої локалізації дефектного об'єкта.

У блок 1 є початком алгоритму: після завершення робочого циклу промислового робота приймається сигнал початку перевірки наявності аномалій процесу роботизованого вкладання.

Блок 2 ініціює цикл перебору зображень всіх палетованих флаконів до кінцевого значення I.

Блок 3 захоплює кадр з промислової камери, що містить поточний стан секцій флаконів на палеті.

У блоці 4 виконується геометричне вирівнюванню над зображенням за допомогою гомографічної трансформації, яка розраховується по маркерах робочої поверхні. При цьому усуваються монтажні похибки розташування камери, а координатна сітка кадру однозначно співвідноситься з теоретичними комірками палети.

Блок 5 застосовує нормалізацію яскравості такими інструментами як: гістограмне вирівнювання та баланс білого за сірим. Ці корекції зменшують вплив нестабільного світлового потоку та спектральних флуктуацій.

У блоці 6 на нормалізованому кадрі виділяється Region of Interest (ROI) для зменшення зони аналізу кадру.

Далі виконається блок 7, де проводиться обробка кадру ШНМ детектором з використанням засобу глибинного навчання. Результатом є множина обмежувальних рамок із оцінками впевненості.

На висновках ШНМ, у блоці 8, відбувається алгоритм подавлення немаксимальних детектувань (NMS – non-maximum suppression), яка має відфільтровувати дублікати.

Додаткової точності надає блок 9 у якому проводиться кластеризація, яка повинна за центроїдами кластерів розрізнити близько розташовані об'єкти.

У блоці 10 виконується порогова фільтрація шляхом порівняння значення довіри виявленої аномалії з заданим порогом, установленим статистичним аналізом помилок першого та другого роду. У випадку значень менших за порогове значення, алгоритм переходить до блоку 11, де інкрементується змінна циклу і повторює цикл. У випадку перевищення

порогового значення – ШНМ виявила аномалію, передала її наступному модулю і перейшла на повторне проведення детектування аномалій на знімку, повторний аналіз зображення буде відбуватись допоки ШНМ не перестане виявляти нових аномалій

Алгоритм завершується на блоці 12, коли всі флакони були проаналізовані, тобто $V_i = I$.

2.3 Алгоритм сегментування аномалій інтелектуалізованою системою детектування та аналізу аномалій роботизованого палетування

Набір даних з координатами виявленої аномалії подаються на наступний процес – сегментацію аномалії. Алгоритм сегментування аномалій інтелектуалізованою системою детектування та аналізу аномалій роботизованого палетування наведено на рис.2.3.




Рисунок 2.3 – Алгоритм сегментації аномалій інтелектуалізованою системою детектування та аналізу аномалій

Алгоритм сегментації аномалії призначений для точного виділення контурів аномалії.

Блок 1 окреслює початок алгоритму сегментації аномалії. На початку подається набір даних, що складається з зображення, висновку НМ детектора і внутрішніх міток, таких як час.

Блок 2 задає початок циклу, в якому перебираються всі знайдені аномалії V_a .

У блоці 3 на основі отриманого обмежувального прямокутника з алгоритму виявлення аномалії формується ROI, збільшений на декілька відсотків для компенсації можливої систематичної похибки детектора.

Після цього, у блоці 4 ROI масштабується до уніфікованого розміру і для моделі сегментації формується вхідний шаблон.

Блок 5 виконує сегментацію ШНМ і повертає бінарну маску, що позначає пікселі аномального флакона.

Над маскою у блоці 6 проводиться обробка морфологічною послідовністю ерозії: розширення та заповнення множин.

Блок 7 збільшує значення V_a на 1, тим самим перебираючи всі аномалії з кількості A .

Алгоритм завершується на блоці 8. Результатом роботи алгоритму є бінарне зображення (маска аномалії), уточнена рамка і ідентифікатор комірки.

2.4 Алгоритм аналізу аномалії інтелектуалізованою системою детектування та аналізу аномалій



Рисунок 2.4 – Алгоритм роботи модуля інтелектуалізованого аналізу аномалії

Алгоритм починається з блоку 1. У блоці 2 алгоритм інтелектуалізованого аналізу отримує бінарну маску аномалії, уточнений обмежувальний прямокутник та ідентифікатор комірки і за допомогою часової мітки вони синхронізуються з реальним просторовим станом палети.

Блок 3 проводить над даними процедуру обрахунку точку затиску C_{VI} методом головних компонент У блоці 4 визначається вектор орієнтації флакона O_{VI} , кут орієнтації його головної осі у площині зображення.

Після чого, у блоці 5 вектор просторового положення і параметр орієнтації переноситься з системи координати камери у систему координати інструмента робота за допомогою зовнішньої каліброваної матриці.

Блок 6 є кінцевим блоком алгоритму. Точка захвату разом із просторовими координатами C_{VI} та орієнтаційною інформацією O_{VI} , який за допомогою стандартизованого протоколу Ethernet передається до модуля роботизованої корекції.

3. ФОРМУВАННЯ НАВЧАЛЬНОГО НАБОРУ ДАНИХ ДЛЯ ІНТЕЛЕКТУАЛІЗОВАНОЇ СИСТЕМИ ДЕТЕКТУВАННЯ І ВИЯВЛЕННЯ АНОМАЛІЙ В ПРОЦЕСІ РОБОТИЗОВАНОГО ПАЛЕТУВАННЯ ФЛАКОНІВ

3.1 Збір навчального набору даних з аномаліями

Для ефективної роботи НМ критично потребує проведеного якісного навчального процесу. Приклад набору навчальних даних для ШНМ наведено на рис.3.1.




Рисунок 3.1 – Приклад набору даних з аномальними подіями трьох форматів пластикових флаконів: 100мл, 250мл, 500мл

Для забезпечення коректності машинного навчання до набору зображень висувається перелік умов – охоплення повного спектру робочих умов: варіювання освітлення, ракурсів, масштабів, фокусних відстаней, фонових текстур. Роздільна здатність кадрів повинна бути не нижчою за мінімально-критичну для цільової задачі, а якості самого набору мають бути описані в метаданих. Розподіл даних має співвідноситись з реальною частотою подій по класах.

Отже, було зібрано набір даних з аномаліями упродовж роботи системи в режимі ручного коригування аномалій.

3.2 Анотування навчального набору даних

Найвищі вимоги висуваються до анотацій: просторові контури об'єктів повинні мати високу точність, а семантичні ярлики – бути узгодженими між різними розмітниками. Анотоване зображення наведено на рис.3.2.




Рисунок 3.2 – Зображення з анотованими аномаліями

Приклад анотацій створених в програмному забезпеченні з відкритим кодом VGG Image Annotator [24], наведено у форматі csv:

```
filename,file_size,file_attributes,region_count,region_id,region_shape_attributes,region_attributes
-----
anomalies_56.jpg,288568,"{}",8,0,"{"name":"rect","x":373,"y":310,"width":123,"height":97},"{}"
anomalies_56.jpg,288568,"{}",8,1,"{"name":"rect","x":288,"y":436,"width":135,"height":81},"{}"
anomalies_56.jpg,288568,"{}",8,2,"{"name":"rect","x":367,"y":530,"width":129,"height":79},"{}"
anomalies_56.jpg,288568,"{}",8,3,"{"name":"rect","x":268,"y":597,"width":92,"height":122},"{}"
anomalies_56.jpg,288568,"{}",8,4,"{"name":"rect","x":554,"y":654,"width":129,"height":88},"{}"
anomalies_56.jpg,288568,"{}",8,5,"{"name":"rect","x":510,"y":406,"width":98,"height":114},"{}"
anomalies_56.jpg,288568,"{}",8,6,"{"name":"rect","x":549,"y":289,"width":132,"height":88},"{}"
```

Однак, ШНМ YOLO вимагає нормалізованих даних про кожну аномалію у форматі (3.1 – 3.4):

$$X_{norm} = \frac{x_{ann} + \frac{w_{rect}}{2}}{W_{im}}, \quad (3.1)$$

$$Y_{norm} = \frac{y_{ann} + \frac{h_{rect}}{2}}{H_{im}}, \quad (3.2)$$

$$H_{norm} = \frac{h_{rect}}{H_{im}}, \quad (3.3)$$

$$W_{norm} = \frac{w_{rect}}{W_{im}}, \quad (3.4)$$

де x_{ann}, y_{ann} – ненормовані координати лівого верхнього куту обмежуючого прямокутника аномалії, X_{norm}, Y_{norm} – нормовані координати центру аномалії, w_{rect} – ширина обмежуючого прямокутника, h_{rect} – висота обмежуючого прямокутника аномалії, H_{im} – висота зображення, W_{im} – ширина зображення, H_{norm} – нормована висота обмежуючого прямокутника аномалії, W_{norm} – нормована ширина обмежуючого прямокутника.

Таким чином, була проведена анотація і нормування зібраного набору даних для тренування ШНМ.

3.3 Аугментація тренувального набору зображень аномалій

ШНМ має бути стійкою для змін і мати якість універсальності до умов робочого середовища. З цією метою виконується модифікація набору навчальних даних, які включають в себе зміну певних характеристик, додавання елементів на знімки, морфологічні зміни.

Просторові аугментації виконано за допомогою бібліотеки `albumérations` [25], з використанням мови `python`. З бібліотеки використані наступні аугментації:

- `AdditiveNoise` — додає до пікселів адитивний шум із заданим діапазоном амплітуд;
- `AdvancedBlur` — моделює складні схеми розмиття (комбінації `Gaussian`, `motion`- та `defocus-blur`);
- `AutoContrast` — автоматично розтягує гістограму яскравостей на повний динамічний діапазон;
- `Blur` — класичне розмиття із керованим радіусом ядра;
- `CLAHE` — локальне вирівнювання гістограми з обмеженням контрасту;
- `ChromaticAberration` — імітує оптичні хроматичні аберації;
- `ColorJitter` — випадково змінює яскравість, контраст, насиченість і відтінки;
- `GaussNoise` — додає гаусівський шум із заданою дисперсією;
- `GaussianBlur` — чистий `Gaussian-blur` зі змінним σ ;
- `ISONoise` — моделює фотошум сенсора при високих значеннях ISO;
- `Posterize` — зменшує кількість біт на канал, вводячи бандінг;
- `RandomFog` — накладає туман із довільною щільністю й градієнтом по глибині;
- `RandomGamma` — випадково змінює показник степеню γ -корекції;

- RandomGravel — додає синтетичні «камінці»/зерна випадкового розміру та щільності;
- RandomShadow — накладає полігональні або еліптичні тіньові області;
- RandomSnow — імітує снігопад з яскравими плямами-пластівцями;
- SaltAndPepper — імпульсний шум «сіль-перець» зі заданою щільністю;
- SaltAndPepper — імпульсний шум «сіль-перець» зі заданою щільністю.

Основні використані аугментації для навчального набору даних для ШНМ наведено на рис.3.3.




Рисунок 3.3 – Приклад аугментацій, застосованих до навчального набору зображень для навчання ШНМ

Одним із ключових підходів до підвищення ефективності навчання ШНМ є збільшення обсягу і різноманіття навчального набору зображень за допомогою методів аугментації зображень. У межах роботи було реалізовано як одиночне, так і комбіноване застосування аугментацій до зібраного набору зображень. Такий підхід дозволяє значно розширити навчальний матеріал для ШНМ без дублювання зображень або створення нових вручну зібраних даних. Аугментації моделюють варіації зображень, що можуть виникати у реальних виробничих умовах, зберігаючи при цьому загальну структуру об'єктів та їхню семантичну значущість.

Також використання сегментації дозволяє зменшити ризик перенавчання, як наприклад при дублюванні зображень. Задля підвищення надійності та стійкості моделі до хибно-позитивних спрацювань, до навчального набору даних було додано зображення без аномалій. Таки зображення слугують фоновими прикладами і являються важливим елементом при навчання ШНМ вирізнення нормального стану від потенційних аномалій.

Таким чином, було сформовано набір даних з зображень реальних аномалій на всі три типи флаконів, у рівній кількості кожного типу. Додатково додано фонові зображення у співвідношенні 10:30:30:30 (де 10% – фонові зображення, 30% – зображення аномалій кожного формату флаконів). До кожного зображення випадковим чином застосовувались аугментації, що охоплювали трансформації за кольором, яскравістю, різкістю, шумами, просторовими характеристиками. Нормальне зображення при цьому залишалось у загальному навчальному наборі даних.

4. ПРОГРАМНЕ ЗАБАЗПЕЧЕННЯ ІНТЕЛЕКУАЛІЗОВАНОЇ СИСТЕМИ ДЕТЕКТУВАННЯ НА АНАЛІЗУ АНОМАЛІЙ РОБОТИЗОВАНОГО ПАЛЕТУВАННЯ ФАРМАЦЕВТИЧНИХ ФЛАКОНІВ

4.1 Архітектура штучної нейронної мережі YOLOv12

Родина ШНМ «YOLO» постійно вдосконалюється, і YOLOv12 [26] являє собою наступний етап її розвитку, який орієнтований на підвищення точності. Архітектура ШНМ складається з трьох модулів: опорну мережу (backbone), з'єднувальний блок (neck), вихідний блок (head). Архітектура наведена на рис.4.1.




Рисунок 4.1 – Архітектура ШНМ YOLOv12 для детектування аномалій

Ключовим в опорній мережі є застосування Residual Efficient Layer Aggregation Network (R-ELAN), який усуває ризики затухання під час навчання НМ використовуючи роздільні згортки 7×7 . Таке впровадження зменшило обчислювальну складність при такому ж глобальному просторовому контексті. Використання пірамідальної багато масштабної

репрезентації ознак формує стійкі дескриптори для дрібних об'єктів завдяки наявності шарів різної роздільної здатності.

З'єднувальний блок використовує механізм Area Attention задля агрегації багатомасштабних ознак. Замість використання окремих пікселів цей механізм виконує операції компактними регіонами зі зниженої квадратичною складністю і розширеним ефективним полем зору. Розрахунок проводиться за формулою 4.1:

$$Att(O, P, C) = softmax\left(\frac{OP^T}{\sqrt{r_k}}\right) C, \quad (4.1)$$

де O – матриця запитів, P – матриця ключів, C – матриця значень, r_k – розмірність ключів.

Вихідний блок перетворює виділені ознаки на координати обмежувальних прямокутників та класові ймовірності. Він поєднує у собі декілька оптимізованих методів прогнозування, головним з яких виступає покращена сукупна функція витрат DIoU-Loss із динамічним балансуванням ваг [27].

Новітня архітектура YOLOv12 забезпечила високу продуктивність на дрібних об'єктах, знизило вимоги пам'яті та енергії під час обробки зображень і надало можливість працювати з частотою понад 120 кадрів/с на сучасних GPU.

4.2 Архітектура штучної нейронної мережі SAM

ММ SAM, створена Meta AI, стала фундаментальною моделлю сегментації з підтримкою підказок. Мережа складається з трьох основних частин: енкодер зображення (Image Encoder); декодер масок (Mask Decoder); декодер масок (Prompt Encoder).

Блок енкодеру зображення використовує технологію Vision Transformer (ViT), який натренувати за допомогою Masked Autoencoders (MAE). Цей блок обробляє вхідне зображення і формує щільне векторне представлення, що

відображає семантичну і просторову інформацію. Ця технологія допомагає моделі працювати з зображеннями високої роздільної здатності і видобувати їх ознаки.

Блок енкодеру підказок перетворює підказки, надані користувачем, у векторні представлення. Точки, прямокутні рамки кодуються за допомогою позиційних кодувань і вивчених векторів, а текст обробляється текстовим енкодером CLIP. Існуючі маски вбудовуються через згорткові шари і підсумовуються елемент за елементом з вектором зображення.

Блок декодеру масок має за основу трансформер, який об'єднує вектори зображення та підказок для побудови сегментаційних масок. Задля ефективного поєднання інформації від підказок і ознак зображення блок використовує механізми self-attention та cross-attention. Декодер генерує одну або кілька масок, включаючи неоднозначні випадки. Архітектура SAM [28] наведена на рис. 4.2




Рисунок 4.2 – Архітектура ШНМ SAM

Ключовими особливостями використання SAM є можливість сегментації за підказками типу точки, рамки, маски та текст. Завдяки цьому НМ може генерувати сегментаційні маски відповідно до введених даних. Також, оскільки вона натренована на наборі даних SA-18, що включає у себе понад 11 мільйонів зображень, НМ здатна узагальнювати на зображеннях нового типу без додаткового навчання. Вона часто перевершує повністю

контрольовані моделі в Zero-shot сценаріях. SAM є універсальною, масштабованою моделлю, що оптимізована для роботи в режимі реального часу.

4.3 Оптимізація навчання штучної нейронної мережі

Алгоритми оптимізації використовуються в ШНМ задля мінімізації втрат моделей шляхом коригування параметрів моделі, наприклад, вага і швидкість навчання.

Одним з таких оптимізаторів є стохастичний градієнтний спуск (SGD – Stochastic Gradient Descent). Для i -ої аномалії названою x з міткою y він описується рівнянням наведеним у (4.2) з кроком часу k .

$$\vartheta_{k+1} = \vartheta_k - \varphi_k \cdot \nabla_{\vartheta} J(\vartheta_k), \quad (4.2)$$

де ϑ – параметри моделі, $\nabla_{\vartheta} J$ – цільова функція втрат, φ – швидкість навчання. Алгоритм швидкий, а його флуктуації дозволяють переходити з одного локального мінімуму до більш точного, але пошуки глобального максимуму ускладнені.

До нього згодом була додана умова Нестерова [29], яка ввела механізм імпульсу (momentum), такий що тримає експоненціальне спадаюче середнє минулих градієнтів. SGD with Momentum – SGDM виглядає наступним чином (4.3).

$$\vartheta_{k+1} = \vartheta_k - \varphi_k \cdot \nabla_{\vartheta} J(\vartheta_k + \delta M_{k+1}), \quad (4.3)$$

$$M^{(d+1)} = \delta M^{(d)} + (1 - \varepsilon) \cdot (\nabla_{\vartheta} J(\vartheta_k) + \lambda \vartheta^{(k)}), \quad (4.4)$$

де ε – коефіцієнт демпфування, а M – імпульс.

Також однією з популярних варіацій SGD є AdaGrad, він вирізняється адаптивним розміром кроку і значно пришвидшує швидкість навчання, при цьому зменшуючи затрати на час [30]. AdaGrad наведено у (4.5) та (4.6)

$$\vartheta_{k+1} = \vartheta_k - \frac{\varphi_k}{\sqrt{SG_{k+1} + \gamma}} \cdot \nabla_{\vartheta} J(\vartheta_k), \quad (4.5)$$

$$SG_{k+1} = SG_k + \nabla_{\vartheta} J(\vartheta_k)^2, \quad (4.6)$$

де SG_{k+1} – сума градієнтів.

Алгоритми SGD використовуються у технологіях ШНМ таких як АЕ, CNN та графові ШНМ. Одна з їх ключових проблем – досягнення глобального мінімуму, оскільки вони мають недостатню інформативність щодо функції втрат. Рух за напрямком градієнту не завжди достатньо точний про оброби текстових або візуальних даних.

Більш точним є використання оптимізаторів Adam та його модифікацій. Оптимізатор Adam поділяє швидкість навчання експоненційно спадаючим середнім квадратних градієнтів. Адаптивне навчання прораховується спадаючим середнім за певний крок часу k наведене у (4.7) – (4.10).

$$m_k = \gamma_1 m_{k-1} + (1 - \gamma_1) b_k \quad (4.7)$$

$$v_k = \gamma_2 m_{k-1} + (1 - \gamma_2) b_k^2 \quad (4.8)$$

$$\hat{m}_k = \frac{m_k}{1 - \gamma_1^k} \quad (4.9)$$

$$\hat{v}_k = \frac{v_k}{1 - \gamma_2^k}, \quad (4.10)$$

$$\vartheta_k = \vartheta_{k-1} - \frac{M \hat{m}_k}{\sqrt{\hat{v}_k + \epsilon}}, \quad (4.11)$$

де γ_1, γ_2 – моменти, m_k та v_k – експоненційно рухомі середні b_k і b_k^2 відповідно [31].

Більшість його відомих модифікацій безпосередньо впливає на адаптацію кроку і використання зважених середніх. Наприклад, Adam з L^2 -регуляризацією. Оскільки градієнт регуляризатора масштабується, то ваги не затухають із тим самим ефектом як при розділеному ваговому розкладу.

Було запропоновано метод AdamW [32], варіація Adam з чито розподіленим додаванням регуляційного члена (4.12).

$$\vartheta_k = \vartheta_{k-1} - \rho + k \left(\frac{M \hat{m}_k}{\sqrt{\hat{v}_k + \epsilon}} + \lambda \vartheta_k \right), \quad (4.12)$$

де ρ – коефіцієнт масштабу, λ – коефіцієнт L^2 -регуляризації.

Наступною популярною модифікацією є проєкційний Adam – AdamP. Цей оптимізатор оснований на сумі проєкцій градієнту і імпульсних векторів

в тангенційному просторі. Рівняння оптимізатору AdamP наведено на (4.13) – (4.17)

$$b_k = \nabla_{\vartheta} J(\vartheta_{k-1}) + \lambda \vartheta_{k-1}, \quad (4.13)$$

$$m_k = \gamma_1 m_{k-1} + (1 - \gamma_1) b_k \quad (4.14)$$

$$v_k = \gamma_2 m_{k-1} + (1 - \gamma_2) b_k^2 \quad (4.15)$$

$$p_k = \frac{m_k}{i - \gamma_1^k} \quad (4.16)$$

$$\vartheta_k = \vartheta_{k-1} - \rho_k \left(\frac{M \hat{m}_k}{\sqrt{\hat{v}_k} + \epsilon} + \lambda \vartheta_{k-1} \right), \quad (4.17)$$

Використання проєкцій допомагає запобігти надмірним зростанням ваг, інваріантних до масштабу, тобто оптимізатор пригнічує зростання норми ваг шляхом забезпечення сталої швидкості навчання ШНМ.

Найбільш популярний варіант AdaBelief [33] використовує механізм передбачення напрямку поточного градієнту. При відхиленні поточного градієнту від прогнозу, модель менше довіряє спостереженню і зменшує крок, при наближенні до прогнозованого градієнту – збільшує. Цей підхід показав себе з високою точністю на ШНМ навчених із зображеннями. AdaBelief наведено на (4.18) – (4.22).

$$m_k = \gamma_1 m_{k-1} + (1 + \gamma_1) b_k \quad (4.18)$$

$$v_k = \gamma_2 m_{k-1} + (1 - \gamma_2) (b_k - m_k)^2 + \epsilon, \quad (4.19)$$

$$\hat{m}_k = \frac{m_{k-1}}{i - \gamma_1^t} \quad (4.20)$$

$$\hat{v}_k = \frac{v_{t-1}}{i - \gamma_2^t}, \quad (4.21)$$

$$\vartheta_k = \vartheta_{k-1} - \left(\frac{M \hat{m}_k}{\sqrt{\hat{v}_k} + \epsilon} \right), \quad (4.22)$$

Перспективним також є дослідження використання позитивно-негативного імпульсу (PNM – Positive-Negative Momentum). Наприклад автори [34], запропонували метод НВ наведений у (4.23):

$$M_k = \sum_{i=0}^k \beta_3 \beta_1^{k-i} \gamma_i, \quad (4.23)$$

Крім оптимізаторів першого порядку існують оптимізаційні алгоритми другого порядку, наприклад алгоритм оптимізації Ньютонa, наведений у (4.24).

$$\vartheta_{k+1} = \vartheta_k - \nabla^2_{\vartheta} J(\vartheta_k)^{-1} \nabla_{\vartheta} J(\vartheta_k), \quad (4.24)$$

Оскільки навчання буде проводитись на відносно невеликому наборі даних з одним класом, тоді доцільним буде використання оптимізаційної функції Adam.

4.4 Навчання штучної нейронної мережі YOLOv12

Навчання НМ являє собою фундаментальний етап, на якому встановлюються гіперпараметри мережі, такі як: визначення даних і партій даних; оптимізатор і LR-schedule; аугментації; валідація та моніторинг; візуалізація і обладнання (GPU/CPU).

Як було написано раніше, YOLO використовує мозаїчну аугментацію для навчання НМ. Приклад валідаційного набору зображень наведено на рис.4.3.




Рисунок 4.3 – Приклад валідаційного набору даних під час навчання ШНМ YOLOv12

Процес навчання і числові показники якості проведеного навчання ШНМ – метрики – визначаються за допомогою наступних одиниць:

- Істино позитивні (TP – True Positive) – ШНМ виявила реальний об’єкт на зображенні;
- Хибно позитивні (FP – False Positive) – ШНМ виявила не реальний об’єкт на зображенні;
- Істино негативні (TN – True Negative) – ШНМ не виявила об’єктів на зображенні без таких об’єктів;
- Хибно негативні (FN – False Negative) – ШНМ не виявила реальний об’єкти на зображенні.

Метрика Точність (Precision) відображає частку виявлених ШНМ справжніх аномалій по відношенню до усіх виявлених об’єктів. Чим вище точність, тим нижче частота помилкових виявлень. Точність розраховується за формулою (4.25).

$$Precision = \frac{TP}{TP+FP}. \quad (4.25)$$

Ймовірність пропуску реальних аномалій визначає метрика повноти (Recall) – частка реальних аномалій з усіх виявлень ШНМ. Формула повноти наведена на (4.26).

$$Recall = \frac{TP}{TP+FN} \quad (4.26)$$

Середнє гармонічне між повнотою та точністю виражає метрику F1-score, яка обраховується за формулою (4.27):

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4.27)$$

Метрика перетину над регіонами (IoU – Intersection over Union) визначає наскільки точно передбачувана обмежувальна область сходиться з реальним об'єктом і обраховується за формулою (4.28):

$$IoU = \frac{A_{real} \cap A_{predicted}}{A_{real} \cup A_{predicted}}, \quad (4.28)$$

де A_{real} – дійсна обмежувальна область, $A_{predicted}$ – передбачувана ШНМ область.

Якщо для кожного значення впевненості ШНМ обраховувати метрики, а потім зіставити їх у координату (Точність; Повнота), то можна відобразити поведінку моделі при всіх можливих налаштуваннях порогу впевненості як графік *PR*-кривої. Площа під такою кривою виражає метрику *AP* – Average Precision. Середнє арифметичне *AP* всіх класів об'єктів відображає значення ключової метрики – *mAP* – mean Average Precision, формулу якої наведено у (4.29):

$$mAP = \frac{1}{N_c} \sum_i^{N_c} \frac{TP_i}{TP_i + FP_i}, \quad (4.29)$$

де N_c – кількість класів.

Графічне відображення процесу навчання ШНМ YOLOv12 є комбінацією метрик і функцій втрат, які автоматично генерує бібліотека ultralytics [35] наведено на рис.4.4.




Рисунок 4.4 – Графіки функцій втрат і метрик процесу навчання ШНМ YOLOv12

Під час навчання за 100 епох функції втрат змінювались наступним чином:

- train/box_loss: відображає помилку регресії обмежуючих рамок на тренувальному наборі даних. Від 1,3 вона монотонно спадає до 0,6, що свідчить про поступове покращення точності прив'язування рамок;
- train/cls_loss: відображає класову помилку, за перші п'ять епох спадає з 4 до 0,5 і далі асимптотично наближається до 0,1;
- train/dfl_loss: відображає просторове уточнення центру рамок (DFL – Distribution Focal Loss). Зменшується від 1,3 до 0,9, що свідчить про збільшення точності визначення центроїдів пікселів;
- val/box_loss: відображає помилку регресії обмежуючих рамок на валідаційному наборі даних. Спадає з 1,6 до 0,7, що може свідчити про відсутність перенавчання;
- val/cls_loss: Класова помилка на валідаційному наборі даних демонструє покращення можливості узагальнювання ШНМ;
- val/dfl_loss: Валідаційна DFL за спадаючою кривою свідчить, що просторові помилки узгодженні на обох вибраних наборах даних.

Показники метрик змінювались наступним чином:

- metrics/precision (B): точність граничних рамок на валідаційному наборі даних. Після третьої епохи зростає від 0,95 до 0,99, що свідчить про малу кількість FP;
- metrics/recall (B): Стрімко зростає з 0,7 до 0,99. Модель знаходить майже всі аномалії;
- metrics/mAP50(B): При порозі IoU > 0,5 модель вже після десятої епохи досягає значення 0,98;
- metrics/mAP50-95(B): При значенні IoU від 0,5 до 0,95 поступово підніметься з 0,45 до 0,9.

Криві метрик F1 та повноти за порогами впевненості наведено на рис.




Рисунок 4.6 – Криві F1–Confidence та Recall–Confidence навченої моделі YOLOv12.

Модель надає крайнє високі показники точності та повноти при порозі 0,5 – 0,85, модель визначає всі аномалії. При підвищенні порогу модель починає «фільтрувати» навіть справжні аномалії.

4.5 Пошук точки затиску флакону

Вхідними даними програмного забезпечення інтелектуалізованого аналізу аномалії є бінарна маска флакона. Приклад бінарної маски наведено на рис. 4.7.



Рисунок 4.7 – Бінарна маска аномалії процесу роботизованого палетування фармацевтичних флаконів.

Бінарна маска являє собою зображення яке складається з пікселів флакона – «1» та пікселів фону – «0». Математичне представлення маски: $M(x, y) \in \{1, 0\}$.

Початково, над маскою проводяться морфологічні операції. Морфологічна фільтрація маски – спрощення форми і структури об'єкту сегментованої бінарної маски задля виділення об'єктів інтересу. У випадку кольорового зображення можливо проводити морфологічну фільтрацію кожного шару окремо, у випадку бінарної маски – достатньо одної.

Існує дві базові морфологічно операції:

- Ерозія (Erosion) – зменшення об'єктів шляхом згладження їх меж;
- Розширення (Dilation) – збільшення об'єктів шляхом заповнення щілин і поєднанням дрібних об'єктах на малих відстанях.

Процес розширення схожий до згортки зображення, де структуруючий елемент χ – зазвичай прямокутна матриця 3×3 – проходить по зображенні і у випадку потрапляння на центр χ пікселю об'єкта виконує операцію «Логічне АБО» між пікселями χ та пікселями об'єкта і перетворює зайнятий ним піксель на піксель об'єкта, у випадку потрапляння на фон – ігнорує. Таким чином, жодний піксель об'єкту не зникає, а його межі розширюються, що дозволяє заповнити дрібні отвори.

Процес ерозії маски робить протилежні до розширення дії: у випадку потрапляння центру χ на піксель об'єкту, то при наявності хоча б одного

пікселя фону в області χ , центр перетворюється на піксель фону. Таким чином, контури об'єкта зменшуються, а дрібні об'єкти стираються.

Комбіноване використання цих операцій один за одним створює складніші ефекти:

- Відкриття (Opening) – операція ерозії з наступним розширенням;
- Закриття (Closing) – операція розширення з наступною ерозією.

Базові операції ерозія та розширення, а також їх комбінації виконані над бінарною маскою з трьома колами наведені на рис 4.8.




Рисунок 4.8 – Морфологічні операції над бінарними масками з трьома кулями і наявним шумом

Таким чином, якщо сегментована аномалія може мати шум, тоді необхідно виконати ерозію, після чого можна уточнити межі об'єкту використанням розширення, що разом утворює операцію відкриття області.

Площа маски є сумою пікселів флакону і обраховується за формулою (4.30):

$$S = \sum_{x,y} M(x,y) \quad (4.30)$$

Точкою захвата флакону є точка центру мас флакону – ценроїд $c = (\bar{x}, \bar{y})$, координати якого розраховується за формулами (4.31) та (4.32).

$$\bar{x} = \frac{1}{S} \sum_{x,y} x \cdot M(x,y) \quad (4.31)$$

$$\bar{y} = \frac{1}{S} \sum_{x,y} y \cdot M(x, y) \quad (4.32)$$

Для розрахунку орієнтаційного вектору необхідно визначити коваріаційну матрицю мари точок K за формулою (4.33):

$$K = \begin{bmatrix} \mu_{xx} & \mu_{xy} \\ \mu_{xy} & \mu_{yy} \end{bmatrix}, \quad (4.33)$$

де $\mu_{xx}, \mu_{xy}, \mu_{yy}$ – члени матриці і розраховуються за формулами (4.34) – (4.36):

$$\mu_{xx} = \frac{1}{S} \sum_{x,y} (x - \bar{x})^2 \cdot M(x, y) \quad (4.34)$$

$$\mu_{yy} = \frac{1}{S} \sum_{x,y} (y - \bar{y})^2 \cdot M(x, y) \quad (4.35)$$

$$\mu_{xy} = \frac{1}{S} \sum_{x,y} (x - \bar{x})(y - \bar{y}) \cdot M(x, y) \quad (4.36)$$

Головна вісь флакону, в еліптичному представлені, буде власний вектор матриці з найбільшим власним значенням матриці K , $e_{max} = (e_x, e_y)^T$. Далі необхідно обчислити скалярну проєкцію p_i кожної точки s_i на головну вісь за формулою (4.37):

$$p_i = e_{max}^T \cdot (s_i \cdot c) \quad (4.37)$$

Нехай $r > 0$ – окіл точки, тоді для довільної точки q локальна густина в околі точки визначається як кількість пікселів маски, що лежать не далі ніж r пікселів від q за формулою (4.38):

$$dens_r(q) = |\{i : \|s_i - q\|_2 \leq r\}|. \quad (4.38)$$

Пошук точки кінця флакону біля ковпачку P_{cap} визначається як точка з найменшою локальною щільністю. Тоді орієнтаційний вектор V_x буде одиничним вектором, що спрямований від центроїда c до точки ковпачка P_{cap} і розраховується за формулою (4.39):

$$V_x = \frac{P_{cap} - c}{\|P_{cap} - c\|_2}. \quad (4.39)$$

Аналогічним чином взявши за e_{min} власний вектор з найменшим власним значенням матриці K , розрахувавши граничну точку флакона по вектору e_{min} , орієнтаційний вектор V_y обчислюється за формулою (4.40):

$$V_y = \frac{P_{edge-c}}{\|P_{edge-c}\|_2} \quad (4.40)$$

Якщо розширити вектори координатою глибини, прийнявши її за дно палети, певне значення z . тоді орієнтаційний вектор V_z обчислюється за формулою (4.41).

$$V_z = \frac{V_x \times V_y}{\|V_x \times V_y\|_2} \quad (4.41)$$

Після обрахунку C_{VI} та O_{VI} необхідно зробити переведення системи координат зображення у систему координат робота задля можливості надання команд роботизованої корекції.

Переведення координат з координат реального світу X_{real} до координат зображення X_{image} відбувається завдяки множенню останніх на матрицю проєкції камери H , наведений у формулі (4.42).

$$X_{image} = H \cdot X_{real}, \quad (4.42)$$

Матриця H розраховується за формулою (4.43):

$$H = K \times N, \quad (4.43)$$

де K – матриця внутрішніх параметрів камери, N – матриця зовнішніх параметрів камери.

Матриця зовнішніх параметрів переводить системи координат світу X_{real} до системи координат камери X_{camera} , вона складається з послідовного тривимірного перетворення та тривимірного повороту наведеного у формулі (4.44).

$$N = [R|t] = \begin{bmatrix} I & \mathbf{t} \\ \mathbf{0} & 1 \end{bmatrix} \times \begin{bmatrix} R & \mathbf{0} \\ \mathbf{0} & 1 \end{bmatrix}, \quad (4.44)$$

де I – одинична матриця 3×3 , $\mathbf{t}$ – вектор переміщення, R – матриця повороту.

Після спрощень матриця N набуває вигляду (4.45):

$$N = \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_x \\ r_{21} & r_{22} & r_{23} & t_y \\ r_{31} & r_{32} & r_{33} & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.45)$$

Оскільки зображення є нормалізованою площиною, то воно не має в собі координати z , тобто $z = \text{const}$. Тому в матриці N прибирається останній рядок і відбувається перехід координат від тривимірних до двовимірних. Остаточний вигляд матриці наведений у (4.46).

$$N = \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_x \\ r_{21} & r_{22} & r_{23} & t_y \\ r_{31} & r_{32} & r_{33} & t_z \end{bmatrix} \quad (4.46)$$

Матриця K використовується для переведення координат з системи координат камери до піксельної системи координат, вона складається з матриці двовимірного переміщення, матриці двовимірного масштабування та матриці двовимірного зсуву, наведених на формулі (4.47):

$$K = \begin{bmatrix} 1 & 0 & c_x \\ 0 & 1 & c_y \\ 0 & 0 & 1 \end{bmatrix} \times \begin{bmatrix} f_x & 0 & 0 \\ 0 & f_y & 0 \\ 0 & 0 & 1 \end{bmatrix} \times \begin{bmatrix} 1 & \frac{s}{f_x} & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (4.47)$$

Зазвичай в сучасних камерах пікселі квадратні та майже не мають зсуву між координатними осями X та Y , що дозволяє позбутись множника зсуву s і спросити формулу (4.47) до вигляду (4.48):

$$K = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \quad (4.48)$$

Прямий зворотній перехід від X_{image} світу до X_{real} за формулою обернених до (4.42) неможливий, оскільки необхідно отримати додаткову координату глибини – z .

Тому перехід буде відбуватись за іншою методикою. Спочатку відбувається перехід X_{image} до X_{camera} через обрахунок матриці K методом калібрування камери шаховою дошкою наведений у [31]. Це дозволить обчислити коефіцієнт переходу $k_{conversion}$ пікселів до міліметрів за формулою (4.49)

$$k_{conversion} = \frac{W_{mm}}{W_{pxl}}, \quad (4.49)$$

де W_{mm} – ширина каліброваного зображення у мм, W_{pxl} – ширина каліброваного зображення у пікселях. Тоді координати $(x_{mm}; y_{mm})$ в X_{camera}

будуть обраховані шляхом множення $(x_{pxl}; y_{pxl})$ на цей коефіцієнт (4.50) та (4.51):

$$x_{mm} = x_{pxl} \times k_{conversion} \quad (4.50)$$

$$y_{mm} = y_{pxl} \times k_{conversion} \quad (4.51)$$

Наступним етапом є вимірювання зміщення центру координат камери X_{camera} від центру координат робота X_{robot} . Зазвичай така функція є автоматизованою, і сучасне ПЗ робота, при розміщені на одній осі і знаходженні в одній мережі, може надати камері калібрувальні параметри, що автоматично прорахує матрицю R та вектор t . Маючи R та t можна перевести $(x_{mm}; y_{mm})$ у $(x_{robot}; y_{robot})$ за формулою (4.52):

$$\begin{bmatrix} x_{robot} \\ y_{robot} \end{bmatrix} = R \times \begin{bmatrix} x_{mm} \\ y_{mm} \end{bmatrix} + \begin{bmatrix} t_x \\ t_y \end{bmatrix} \quad (4.52)$$

Орієнтаційні вектори за формулою (4.53).

$$V_{robot} = R \times V_{camera} \quad (4.53)$$

Оскільки координата глибини z є невідомою з інформації наявної на зображенні, то буде використане фіксоване припущення висоти і адаптивний алгоритм взяття пляшки. Механізм взяття пляшки пневматичний, а отже при появі флакона на пневматичному захваті в магістралі зміниться тиск, таку зміну тиску можуть виявити датчики вакууму і флакон буде вважатись взятим у момент появи сигналу від такого типу датчику.

Наведеними вище розрахунками визначається C_{VI} та O_{VI} на основі яких потім формуються коригуючий вплив алгоритмом роботизованої корекції.

4.6 Моделювання цифрового двійника

Підхід до моделювання систем постійно змінювався з плином часу. В давні часи створення речей проходило без попередніх нарисів і розрахунків, тобто у них не було моделей для створення необхідної системи. Згодом, при появі великої кількості майстрів і ремісників вони почали комунікацію між собою і обмінюватись інформацією про створення об'єкту. У об'єкта з'явився

словесний опис, документація, а згодом і ескіз. З ускладненням створюваних систем необхідно було детально передавати технічну інформацію, як наприклад, габарити. Така вимога призвела до появи креслень, а з доступністю комп'ютерно-інтегрованих системи, появи CAD моделей. Розробка продуктів стала керованою моделлю, тобто машина може інтерпретувати CAD модель і автоматично зробити фізичний бажаний об'єкт.

Однак, одразу після створення продукту зв'язок між фізичним об'єктом втрачається. Задля безперервного зв'язку з фізичною моделлю було запроваджено цифрову модель – двійник, що створило синхронізацію у межах реального-часу.

Кульмінацією розробки систем в майбутньому може стати штучний двійник. Цифровий двійник наразі поєднує у собі віртуальну модель в ПЗ та інформацію з фізичного об'єкту. Якщо до цих складових додати апаратне забезпечення, наприклад, робота. Таке впровадження буде означати, що природа цифрового двійника буде знову перероблена і матиме сутність штучного двійника, або роботизованого двійника. Зміна шляхів створення систем наведена на рис.4.9.



Рисунок 4.9 – Модель еволюції шляхів розробки систем запропонована Б. Текіредоганом [36]

Фізичний виробничий об'єкт в цифровому просторі можна представити як: цифрову модель, цифрову тінь та цифрові двійники.

Цифрова модель являє собою цифрову версію існуючого або проєктованого фізичного об'єкту без будь-якого автоматичного обміну даними.

Цифрова тінь – це така модель, яка в цифровому просторі відображає будь-які зміни з фізичним об'єктом.

Цифровий двійник – це комп’ютерна модель, яка відображає фізичний об’єкт, і яка постійно адаптується до змін в умовах експлуатації, дані про які надходять від фізичних об’єктів. При чому потік даних є повністю інтегрований в обох напрямках. В цифровому двійнику потік даних є автоматичний і синхронізує цифрові двійники з поточним станом реального об’єкту, паралельно надсилаючи командну інформацію до нього[37].

Цифровий двійник для системи роботизованого палетування фармацевтичних флаконів створено на базі CAD-моделі, в середовищі SolidWorks, наведено на рис. 4.10.




Рисунок 4.10 – Цифровий двійник системи автоматичного палетування флаконів

При тому від цифрові двійники відрізняються від симуляції тим, що симуляція передбачує майбутні стани на основі певних заданих початкових

припущеннях. У той час як цифровий двійник слідкує за поточним і минулим станами фізичного об'єкта.

Середовище виконання роботизованої системи палетування фармацевтичних флаконів, RT Toolbox, інтегрується з моделлю, використовуючи додаток MELFAWorks, і постійно обмінюється даними про положення робота, командами керування і даними про виникнення аномалії.

Таким чином, було створено цифровий двійник роботизованої системи палетування фармацевтичних флаконів з інтегрованим модулем детектування та аналізу аномалій.

5. ПЕРЕВІРКА ПРАЦЕЗДАТНОСТІ РОЗРОБЛЕНОЇ СИСТЕМИ ІНТЕЛЕКТУАЛІЗОВАНОГО ДЕТЕКТУВАННЯ І АНАЛІЗУ АНОМАЛІЙ РОБОТИЗОВАНОГО ПАЛЕТУВАННЯ ФАРМАЦЕВТИЧНИХ ФЛАКОНІВ

5.1 Детектування аномалій процесу роботизованого палетування фармацевтичних флаконів

Перевірку працездатності тренованої ШНМ YOLOv12 було проведено на наборі даних з 600 зображень, де присутні аномалії у кількості від 1 до 6. Також задля перевірки частоти появи FN було додано зображення без аномалій. Результати детектування аномалій наведено на рис.5.1.




Рисунок 5.1 – Результат детектування аномалій з обмежуючими прямокутниками на тестовому наборі даних, де a та h – зображення без аномалій, b та i – зображення з однією аномалією, c – зображення з двома аномаліями, d – зображення з трьома аномаліями, e – зображення з чотирма аномаліями, f – зображення, що містить п'ять аномалій, g – зображення з шістьма аномаліями.

Таким чином, мережа здатна розрізняти аномалії навіть при накладанні їх одну на одну. Тестування проводилося на робочій станції з процесором Intel(R) Core(TM) i7 і 32 ГБ оперативної пам'яті, а також на виділеній відеокарті NVIDIA RTX 3070 з підтримкою CUDA для прискорення навчання мереж. По кожному зображенню були зібрані дані про аномалію і її обмежуючий прямокутник, які були використані для обчислення метричних показників. Результат роботи ШНМ за кількістю аномалій наведено у таблиці 5.1.

Таблиця 5.1 – Швидкодія та метричні показники детектування аномалій за їх кількістю на зображенні

Кількість аномалій	Precision	Recall	F1 Score	Середній час обробки, с
0	0.000	0.000	0.000	0.056
1	1.000	0.983	0.992	0.056
2	1.000	1.000	1.000	0.057
3	1.000	1.000	1.000	0.056
4	0.995	0.990	0.992	0.056
5	0.991	0.978	0.985	0.057
6	0.993	0.981	0.987	0.056

Загальні показники детектування аномалій дозволяють нам сформулювати матрицю помилок, яка відображає перетин фактичних і передбачуваних значень. Матриця помилок на тестовому наборі даних наведена на рис.5.2.

Факт. позитив	1137	14
Факт. негатив	5	55
	Передб. позитив	Передб. негатив

Рисунок 5.2 – Матриця помилок виявлень ШНМ YOLOv12

Кожна аномалія була анотована за схожим до навчального набору даних методом. Така анотація дозволить обчислити детальну характеристику результатів пошуку аномалій. Графік PR-кривої навченої ШНМ YOLOv12 системи детектування аномалій наведено на рис. 5.3.




Рисунок 5.3 – PR-крива навченої ШНМ YOLOv12 на тестовому наборі даних

Показник AP може бути використаний як узагальнюючий показник точності, він наведений при трьох рівнях перекриття $IoU = 0.5$, $IoU = 0.75$, $IoU \in [0.5; 0.95]$ на рис.5.3




Рисунок 5.4 – графік метрики AP на тестовому наборі даних

Значення $AP@0.5 = 0,983$, $AP@0.75 = 0,972$ свідчить, що модель завжди правильно ідентифікує об'єкти, як при $IoU = 0.5$, так і $IoU = 0.75$. При більш суворішому порозі $IoU \in [0.5; 0.95]$ значення $AP@[0.5:0.95] = 0,816$, що свідчить про стабільну якість на різних порогах і частково може бути пояснена ручною анотацією тестового набору, а компенсована збільшенням обмежуючого прямокутника перед сегментацією.

5.2 Перевірка працездатності модуля інтелектуалізованого аналізу аномалій процесу роботизованого палетування фармацевтичних флаконів

Наступним етапом є передача обмежуючого прямокутника до ШНМ SAM і сегментування тіла флакону з зображення. Результат сегментування наведено на рис. 5.5.

Вхідні зображення

Бінарні маски




Рисунок 5.5 – Результат роботи ШНМ SAM інтелектуалізованої системи виявлення і детектування аномалій роботизованого палетування фармацевтичних флаконів.

Результат роботи SAM без донавчання показує високу точність до виявлення справжніх пікселів флакону від фонового зображення. ШНМ може вирізняти навіть об'єкти розташовані близько один до одного.

Наступним етапом є виконання морфологічних операцій над масками задля згладжування маски флакона для виявлення центру мас і вектору орієнтації. Результат наведено на рис.5.6.




Рисунок 5.6 – Післяобробка маски шляхом виконання морфологічних операцій

В цілому бінарна маска змінюється на 1%, стає гладкішою, зникають зазубрини, одиничні виступи, заповнюються провали. Такі зміни безпосередньо впливають на точність виявлення вектору орієнтації флакону.

Після отримання бінарних масок алгоритм інтелектуалізованого аналізу аномалій проводить обрахунки центру мас і векторів орієнтації флаконів. Результат наведено на рис. 5.7.




Рисунок 5.7 – Графічне представлення результатів алгоритму інтелектуалізованого аналізу аномалій, де жовтий вектор – V_x , синій вектор – V_y , червоне коло – точка затиску флакону

Система інтелектуалізованого аналізу з високою точністю знайшло центри мас флаконів і вектори орієнтації. Текстове представлення результатів наведено у таблиці 5.1.

Таблиця 5.1 – Результат роботи алгоритму інтелектуалізованого аналізу аномалій в системі координат зображення SAM

Флакон	$C_{VI\ SAM}$	$O_{VI\ SAM}$
Рис 5.5, а	(59;39)	(0,995;-0,098)
Рис 5.5, b	(56;41)	(0,909;-0,415)
Рис 5.5, c	(56;56)	(0,867;-0,499)
Рис 5.5, d	(73;61)	(0,852;-0,523)

Наступним кроком є переведення координат у систему координат робота X_{robot} . Координата глибини лотка z дорівнює -1600 у системі координат робота, оскільки робот висить на стелі.

Матриця внутрішніх параметрів камери K розрахована за [31] наведена на (5.1).

$$K = \begin{bmatrix} 1162,38 & 0 & 765,2 \\ 0 & 1163,4 & 520,7 \\ 0 & 0 & 1 \end{bmatrix} \quad (5.1)$$

Коефіцієнт переходу $k_{conversion} = 1,38$. Розташування осі X камери паралельно до осі X робота, а також осі Y камери паралельно осі Y робота, дозволило нехтувати незначні зміщення орієнтаційних векторів. Таким чином, результат роботи алгоритму інтелектуалізованого детектування та аналізу аномалій наведено у таблиці 5.2

Таблиця 5.2 – Результат роботи алгоритму інтелектуалізованого аналізу аномалій в системі координат робота

Флакони	C_{VI}	O_{VI}
Рис 5.5, а	(-76,9;-181,5;-1600)	(0,995;-0,098;0)
Рис 5.5, b	(-12,0;-109,8;-1600)	(0,909;-0,415;0)
Рис 5.5, c	(56,3;-20,1;-1600)	(0,867;-0,499;0)
Рис 5.5, d	(147,8;55,7;-1600)	(0,852;-0,523;0)

Оскільки флакони лежать горизонтально на площині XY , то проекція вектору орієнтації на вісь Z дорівнює нулю: $V \cdot z = V_z = 0$

Таким чином, реалізована інтелектуалізована система детектування і аналізу аномалій роботизованого палетування фармацевтичних флаконів є працездатною і точною у детектуванні факту наявності аномалій та з високим показником загальної точності сегментації і аналізу окремої аномалії.

Дані, отримані з інтелектуалізованої системи, є повним необхідним набором, координата точки затиску та орієнтаційний вектор, задля реалізації автоматичної роботизованої корекції.

ВИСНОВКИ

В магістерській дисертації було підвищено продуктивності технологічного процесу роботизованого палетування та рівня захисту людини на фармацевтичному виробництві шляхом впровадження інтелектуалізованого модуля детектування і аналізу аномалій.

В ході виконання роботи було розроблено структурну схему та алгоритмічне забезпечення інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів.

Для цього було розроблено структурну схему та алгоритмічне забезпечення інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів

Для навчання ШНМ було підготовлено набір навчальних даних фармацевтичного виробництва для інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів.

На основі алгоритмічного забезпечення було розроблено програмне забезпечення для інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів.

В кінці роботи проведено перевірку працездатності розробленої інтелектуалізованої системи детектування та аналізу аномалій в процесі роботизованого палетування фармацевтичних флаконів.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Chaudhary, S., Muthudoss, P., Madheswaran, T., Paudel, A., & Gaikwad, V. (2023). Artificial intelligence (AI) in drug product designing, development, and manufacturing. In *A Handbook of Artificial Intelligence in Drug Delivery* (pp. 395–442). Elsevier. <https://doi.org/10.1016/b978-0-323-89925-3.00015-0>
2. Lee, D.-K., Shin, J.-H., & Lee, D.-H. (2020). Operations scheduling for an advanced flexible manufacturing system with multi-fixturing pallets. In *Computers & Industrial Engineering* (Vol. 144, p. 106496). Elsevier BV. <https://doi.org/10.1016/j.cie.2020.106496>
3. Zoghlami, F., Kurrek, P., Jocas, M., Masala, G., & Salehi, V. (2019). Usage Identification of Anomaly Detection in an Industrial Context. In *Proceedings of the Design Society: International Conference on Engineering Design* (Vol. 1, Issue 1, pp. 3761–3770). Cambridge University Press (CUP). <https://doi.org/10.1017/dsi.2019.383>
4. Graabæk, S. G., Ancker, E. V., Fugl, A. R., & Christensen, A. L. (2023). An Experimental Comparison of Anomaly Detection Methods for Collaborative Robot Manipulators. *IEEE Access*, 11, 65834–65848. <https://doi.org/10.1109/access.2023.3289068>
5. Shuai, Y. (2022). Research on Fault Diagnosis Technology of Industrial Robot Operation Based on Deep Belief Network. *Scientific Programming*, 2022, 1–12. <https://doi.org/10.1155/2022/9260992>
6. Peng, Y.Q. and Chen, D. (2021) Vision-Based Fault Action Detection for Industrial Robots. *Open Access Library Journal*, 8, 1-10. doi:10.4236/oalib.1107189.
7. Alzarooni, A., Iqbal, E., Khan, S. U., Javed, S., Moyo, B., & Abdulrahman, Y. (2025). Anomaly Detection for Industrial Applications, Its Challenges, Solutions, and Future Directions: A Review (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2501.11310>

8. Ali, S., Abuhmed, T., El-Sappagh, S., Muhammad, K., Alonso-Moral, J. M., Confalonieri, R., Guidotti, R., Del Ser, J., Díaz-Rodríguez, N., & Herrera, F. (2023). Explainable Artificial Intelligence (XAI): What we know and what is left to attain Trustworthy Artificial Intelligence. *Information Fusion*, 99, 101805. <https://doi.org/10.1016/j.inffus.2023.101805>
9. Xu, P., Shao, W., Zhang, K., Gao, P., Liu, S., Lei, M., Meng, F., Huang, S., Qiao, Y., & Luo, P. (2025). LVLM-EHub: A Comprehensive Evaluation Benchmark for Large Vision-Language Models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 47(3), 1877–1893. <https://doi.org/10.1109/tpami.2024.3507000>
10. Mohit Jain, Adit Shah, 2024. "*Anomaly Detection Using Convolutional Neural Networks (CNN)*" *ESP International Journal of Advancements in Computational Technology (ESP-IJACT)* Volume 2, Issue 3: 12-22.
11. Jia, H., & Liu, W. (2023). Anomaly detection in images with shared autoencoders. In *Frontiers in Neurorobotics* (Vol. 16). Frontiers Media SA. <https://doi.org/10.3389/fnbot.2022.1046867>
12. Tziolas, T., Papageorgiou, K., Theodosiou, T., Papageorgiou, E., Mastos, T., & Papadopoulos, A. (2022). Autoencoders for Anomaly Detection in an Industrial Multivariate Time Series Dataset. In *The 8th International Conference on Time Series and Forecasting* (p. 23). International Conference on Time Series and Forecasting. MDPI. <https://doi.org/10.3390/engproc2022018023>
13. Yang, C., Lan, S., Huang, W., Wang, W., Liu, G., Yang, H., Ma, W., & Li, P. (2022). A Transformer-Based GAN for Anomaly Detection. In *Lecture Notes in Computer Science* (pp. 345–357). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-15931-2_29
14. Lüer, F., & Bohm, C. (2024). Anomaly Detection using Generative Adversarial Networks Reviewing methodological progress and challenges. In *ACM SIGKDD Explorations Newsletter* (Vol. 25, Issue 2, pp. 29–41). Association for Computing Machinery (ACM). <https://doi.org/10.1145/3655103.3655109>

15. Staar, B., Lütjen, M., & Freitag, M. (2019). Anomaly detection with convolutional neural networks for industrial surface inspection. In *Procedia CIRP* (Vol. 79, pp. 484–489). Elsevier BV. <https://doi.org/10.1016/j.procir.2019.02.123>
16. Lin, W.-J., Chen, J.-W., Jhuang, J.-P., Tsai, M.-S., Hung, C.-L., Li, K.-M., & Young, H.-T. (2021). Integrating object detection and image segmentation for detecting the tool wear area on stitched image. In *Scientific Reports* (Vol. 11, Issue 1). Springer Science and Business Media LLC. <https://doi.org/10.1038/s41598-021-97610-y>
17. Ferguson, M., Ak, R., Lee, Y.-T. T., & Law, K. H. (2018). Detection and Segmentation of Manufacturing Defects with Convolutional Neural Networks and Transfer Learning. In *Smart and Sustainable Manufacturing Systems* (Vol. 2, Issue 1, pp. 137–164). ASTM International. <https://doi.org/10.1520/ssms20180033>
18. Zhao, Q., & Liu, Y. (2024). Design of apple recognition model based on improved deep learning object detection framework Faster-RCNN. In *Advances in Continuous and Discrete Models* (Vol. 2024, Issue 1). Springer Science and Business Media LLC. <https://doi.org/10.1186/s13662-024-03835-2>
19. Sharma, A. K. (2024). Object Detection Model: An Enhanced SSD. In *International Journal for Research in Applied Science and Engineering Technology* (Vol. 12, Issue 5, pp. 1598–1612). International Journal for Research in Applied Science and Engineering Technology (IJRASET). <https://doi.org/10.22214/ijraset.2024.61802>
20. Khanam, R., & Hussain, M. (2024). YOLOv11: An Overview of the Key Architectural Enhancements (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2410.17725>
21. Guo, J., Wang, Z., & Zhang, S. (2023). FESSD: Feature Enhancement Single Shot MultiBox Detector Algorithm for Remote Sensing Image Target Detection. In *Electronics* (Vol. 12, Issue 4, p. 946). MDPI AG. <https://doi.org/10.3390/electronics12040946>
22. Tan, L., Huangfu, T., Wu, L., & Chen, W. (2021). Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification. In *BMC Medical*

Informatics and Decision Making (Vol. 21, Issue 1). Springer Science and Business Media LLC. <https://doi.org/10.1186/s12911-021-01691-8>

23. Wołk, K., & Tatar, M. S. (2024). A Review of Semantic Segmentation and Instance Segmentation Techniques in Forestry Using LiDAR and Imagery Data. In *Electronics* (Vol. 13, Issue 20, p. 4139). MDPI AG. <https://doi.org/10.3390/electronics13204139>

24. Dutta, A., & Zisserman, A. (2019). The VIA Annotation Software for Images, Audio and Video. In *Proceedings of the 27th ACM International Conference on Multimedia. MM '19: The 27th ACM International Conference on Multimedia. ACM*. <https://doi.org/10.1145/3343031.3350535>

25. Buslaev, A., Iglovikov, V. I., Khvedchenya, E., Parinov, A., Druzhinin, M., & Kalinin, A. A. (2020). Albumentations: Fast and Flexible Image Augmentations. In *Information* (Vol. 11, Issue 2, p. 125). MDPI AG. <https://doi.org/10.3390/info11020125>

26. Tian, Y., Ye, Q., & Doermann, D. (2025). YOLOv12: Attention-Centric Real-Time Object Detectors (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2502.12524>

27. Jegham, N., Koh, C. Y., Abdelatti, M., & Hendawi, A. (2024). YOLO Evolution: A Comprehensive Benchmark and Architectural Review of YOLOv12, YOLO11, and Their Previous Versions (Version 4). arXiv. <https://doi.org/10.48550/ARXIV.2411.00201>

28. Zhang, Y., Shen, Z., & Jiao, R. (2024). Segment Anything Model for Medical Image Segmentation: Current Applications and Future Directions (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2401.03495>

29. Dogo, E. M., Afolabi, O. J., Nwulu, N. I., Twala, B., & Aigbavboa, C. O. (2018). A Comparative Analysis of Gradient Descent-Based Optimization Algorithms on Convolutional Neural Networks. In *2018 International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS)* (pp. 92–99). 2018 International Conference on Computational Techniques, Electronics

- and Mechanical Systems (CTEMS). IEEE.
<https://doi.org/10.1109/ctems.2018.8769211>
30. Ward, R., Wu, X., & Bottou, L. (2018). AdaGrad stepsizes: Sharp convergence over nonconvex landscapes. arXiv.
<https://doi.org/10.48550/ARXIV.1806.01811>
 31. Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization (Version 9). arXiv. <https://doi.org/10.48550/ARXIV.1412.6980>
 32. Zhuang, Z., Liu, M., Cutkosky, A., & Orabona, F. (2022). Understanding AdamW through Proximal Methods and Scale-Freeness (Version 1). arXiv.
<https://doi.org/10.48550/ARXIV.2202.00089>
 33. Zhuang, J., Tang, T., Ding, Y., Tatikonda, S., Dvornek, N., Papademetris, X., & Duncan, J. S. (2020). AdaBelief Optimizer: Adapting Stepsizes by the Belief in Observed Gradients. arXiv. <https://doi.org/10.48550/ARXIV.2010.07468>
 34. Abdulkadirov, R., Lyakhov, P., & Nagornov, N. (2023). Survey of Optimization Algorithms in Modern Neural Networks. *Mathematics*, 11(11), 2466.
<https://doi.org/10.3390/math11112466>
 35. Jocher, G., Qiu, J., & Chaurasia, A. (2023, January 10). Ultralytics YOLO (Version 8.0.0) [Software]. Ultralytics. <https://github.com/ultralytics/ultralytics>
 36. De la Escalera, A., & Armingol, J. M. (2010). Automatic Chessboard Detection for Intrinsic and Extrinsic Camera Parameter Calibration. *Sensors*, 10(3), 2027–2044. <https://doi.org/10.3390/s100302027>
 37. Tekinerdogan, B. (2022). On the Notion of Digital Twins: A Modeling Perspective. *Systems*, 11(1), 15. <https://doi.org/10.3390/systems11010015>
 38. Segovia, M., & Garcia-Alfaro, J. (2022). Design, Modeling and Implementation of Digital Twins. *Sensors*, 22(14), 5396.
<https://doi.org/10.3390/s22145396>



ТОВ «ОКТАВІС ІНЖИНІРИНГ»

Код ЄРДПОУ: 40762442

Україна, 02095, м.Київ, вул. Княжий Затон 9-А, офіс 369

тел.: +38 (067)-577-95-75

www.octavis.group

Довідка

про впровадження результатів магістерської дисертаційної роботи
Згурського Д.О. на тему *«Інтелектуалізована система детектування та аналізу
аномалій роботизованого палетування фармацевтичних флаконів»*

ТОВ «ОКТАВІС ІНЖИНІРИНГ» підтверджує, що наукові та практичні результати магістерської дисертаційної роботи Згурського Данила Олеговича в частині інтелектуалізованого детектування та аналізу аномалій роботизованого палетування фармацевтичних флаконів були впроваджені та є невід'ємною частиною автоматичної системи завантаження флаконів, яка розроблена ТОВ «ОКТАВІС ІНЖИНІРИНГ» на замовлення ПРАТ «Фармацевтична фірма «Дарниця».

Інтелектуалізована система детектування та аналізу аномалій інтегрована в систему машинного зору модуля палетування фармацевтичних флаконів, в якій знайшли відображення виявлення аномалій та їхній аналіз. Ці компоненти є складовою програмного забезпечення автоматичної корекції аномалій процесу палетування на основі роботизованих технологій. У рамках рішення реалізовано програмний модуль детектування флаконів, аналізу їхніх геометричних параметрів, а також визначення координат точок затиску для подальшої роботизованої корекції положення флаконів.

Розроблене рішення дозволяє підвищити ефективність процесу палетування шляхом зменшення витрат часу на ручний контроль, який наразі використовується підприємством.

Директор технічний
ТОВ «ОКТАВІС ІНЖИНІРИНГ»



Максим ГНАТЕНКО