

<https://doi.org/10.31891/2219-9365-2024-79-15>

УДК 004.032.26: 004.93'1

МАСТЕНКО Ігор

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

<https://orcid.org/0000-0002-2953-4589>

[ihormas@gmail.com](mailto:ihormas@gmail.com)

СТЕЛЬМАХ Наталія

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

<https://orcid.org/0000-0003-1876-2794>

[n.stelmakh@kpi.ua](mailto:n.stelmakh@kpi.ua)

## ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖ YOLO В СИСТЕМАХ АВТОМАТИЗОВАНОГО КОНТРОЛЮ ЯКОСТІ ПРИ ВИЯВЛЕННІ ДЕФЕКТІВ ВИРОБІВ ОРГАНІЧНОГО ПОХОДЖЕННЯ

*Візуальна інспекція є невід'ємною складовою контролю якості продукції виробництва. Системи машинного зору широко використовуються в різних промислових галузях, займаючи важливе місце в сучасних системах контролю та перевірки якості. Це пов'язано, перш за все, з високим рівнем конкуренції на ринку і зростаючими стандартами до якості продукції. Справжнім викликом став процес контролю якості виробів органічного походження засобами машинного зору, зокрема з використанням нейронних мереж, адже такі вироби містять багато різноманітних дефектів і кожен виріб є унікальним, не схожим на інший. Для вирішення цих задач пропонуються застосування комплексного підходу, а саме технології локалізації та класифікації дефектів виробів засобами нейронних мереж.*

*Ключові слова: дефектоскопія, автоматизована система контролю, якість продукції, машинний зір, глибоке навчання, нейронні мережі.*

MASTENKO Ihor, STELMAKH Nataliia

National Technical University of Ukraine "Ihor Sikorskyi Kyiv Polytechnic Institute"

## APPLICATION OF YOLO NEURAL NETWORKS IN DEFECT DETECTION IN AUTOMATED QUALITY CONTROL SYSTEMS FOR PRODUCTS OF ORGANIC ORIGIN

*Modern technological equipment for various purposes must fully meet the requirements of digital production and be able to quickly integrate into the structure of smart enterprises that are switching to cyber-physical technological systems. Machine vision (MV) is a key element of such systems and a promising automation tool that enables the capture and movement of various objects, including components, quality control, and safety. In addition, machine vision is increasingly being used in modular machine tools. The article analyses various applications of machine vision, in particular, its use in intelligent technological systems for product quality control. Particular attention is paid to fast and efficient quality analysis at the stage of the production process, which allows for accurate defect detection. The article investigates the feasibility of using mathematical models of artificial neural networks to create an intelligent system for monitoring the geometric condition of products. The aim of the study is to identify and classify the quality parameters of products of organic origin, namely reed tubes. For this purpose, new quality control methods based on computer vision and machine learning algorithms are proposed to identify and classify various types of defects using an integrated approach, namely, technologies for localization and classification of product defects using neural networks. As an example, we consider products of organic origin, for which the localisation and classification of defects is difficult due to their natural structure and uniqueness. To solve this problem, the use of neural networks of several YOLO architectures was first proposed. The study presented the results of training two modifications of the YOLOv10s and YOLOv10m neural networks, which were positive.*

*Keywords: flaw detection, automated quality control system, product quality, machine vision, deep learning, neural networks.*

### ПОСТАНОВКА ПРОБЛЕМИ У ЗАГАЛЬНОМУ ВИГЛЯДІ ТА ЇЇ ЗВ'ЯЗОК ІЗ ВАЖЛИВИМИ НАУКОВИМИ ЧИ ПРАКТИЧНИМИ ЗАВДАННЯМИ

Питання організації ефективного контролю якості залишаються ще досі актуальними, оскільки на виробництві все частіше використовують нові види матеріалів, такі наприклад як композитні або комплектуючі для виробів отриманні шляхом застосування адитивних технологій, що в свою чергу потребує особливого постоброблення, та відповідно контролю якості. Використання традиційних методів контролю якості продукції, таких як ультразвукова, магнітна, рентгенівська дефектоскопія, аналіз звукових хвиль для виявлення внутрішніх дефектів у матеріалах все ще залишаються актуальними. Натомість візуальний огляд виробів на предмет видимих дефектів, використовуючи людський фактор, таких як тріщини, подряпини, неправильна форма, втрачає популярність і це пов'язано з додатковими витратами на людську працю та значною мірою залежить від психоемоційного і фізичного стану контролерів. Важливим є також швидкий і ефективний аналіз якості продукції на етапі виробничого процесу, що забезпечує високу точність виявлення дефектів [1].

Тому впровадження сучасних комп'ютерних технологій стає дедалі актуальнішим у інтелектуальних технологічних системах для контролю якості продукції, а також для моніторингу стану технологічних

процесів і виробничого обладнання (верстатів, інструментів тощо). Зокрема, до таких належать **комп'ютерний зір** із застосуванням алгоритмів машинного навчання для автоматичного виявлення і класифікації дефектів та технології **Інтернет речей (IoT)**, а саме сенсори, що аналізують виробничий процес в реальному часі, допомагаючи виявляти аномалії. [2] Детектування та класифікація дефектів виробів є важливими етапами контролю якості на виробництві. У цій статті пропонується підхід, який досягає цих цілей, а саме детектує і класифікує дефекти на виробках органічного походження, та показує високу точність результатів.

### АНАЛІЗ ДОСЛІДЖЕНЬ ТА ПУБЛІКАЦІЙ

Машинний зір є однією з найбільш динамічних областей, що розвивається в інтелектуальних технологіях. За прогнозами, загальний ринок машинного зору в промисловості в США досягне 12,29 мільярдів доларів США до 2023 року [3]. Ці дані вказують на високу потребу великих компаній у впровадженні максимальної автоматизації технологічних процесів, зокрема в операціях контролю якості продукції [4]. Зростання попиту на системи машинного зору обумовлене четвертою промисловою революцією, Індустрією 4.0, а також розвитком таких технологій, як штучний інтелект та Інтернет речей.

Сучасні науковці та розробники пропонують виробництву безліч інструментів для виявлення дефектів продукції, таких як різноманітні датчики, програмне забезпечення SPC, алгоритми штучного інтелекту і машинного навчання, рентгенівські системи, ультразвукові системи та вихрострумові системи. Визначення відповідного інструменту або об'єднання інструментів залежить від характеру дефекту та відповідної виробничої процедури. Певні аномалії можуть вимагати негайного моніторингу та аналізу за допомогою датчиків і програмного забезпечення SPC, в той час як інші можуть вимагати більш всебічного аналізу за допомогою рентгенівських або ультразвукових систем. [5]

Задача автоматизованої сегментації зображень дефектів металевих поверхонь також досить часто розглядається [6]. Метою дослідження є покращення алгоритмів сегментації шляхом використання методів глибокого навчання. Завдяки спеціальній архітектурі, нейронна мережа здатна ефективно генерувати маски сегментації. Навчальний набір даних для мережі містив зображення чотирьох типів дефектів, таких як відколи, тріщини та плями. Аналіз розподілу класів у цьому наборі показав, що класи є незбалансованими, що негативно позначається на процесі навчання.

Можливість застосування моделі глибокого навчання YOLOv5s для автоматизації виявлення поверхневих дефектів на друкованих платах досліджується досліджувалась групою науковців. [7] Модель YOLOv5s була реалізована та навчена для оцінки її ефективності в цьому завданні. Для навчання використовувався відкритий набір даних під назвою «Дефекти друкованих плат». Було проведено як якісний, так і кількісний аналіз продуктивності моделі на тестовому наборі даних. Результати показали, що модель здатна виявляти дефекти на поверхні друкованих плат з точністю 92,5% за показником mAP50. Також був проведений аналіз виявлення різних типів дефектів, після чого запропоновано рекомендації для подальшого вдосконалення системи, зокрема, використання аугментації даних та більш складної архітектури глибокого навчання.

Так у роботі [8] автори представили алгоритм комп'ютерного зору для класифікації яблук. Проведена робота по автоматичному видаленні фону зображень. Використовують сегментацію дефектів за допомогою двошарової нейронної мережі MLP для кожного пікселя на основі його значень R, G, B і H. Відокремлюють кожен об'єкт контролю до відповідної категорії якості, використовуючи 16 витягнутих ознак, включаючи 8 статистичних, 5 текстурних і 3 геометричних ознаки за трьома класифікаторами SVM, MLP і KNN. Результати показують, що після навчання класифікатора SVM на 96 (3 × 32) навчальних зображеннях яблук він досяг найкращої продуктивності 92,5% і 89,2% для двох категорій і трьох категорій якості, відповідно, протягом 24 (3 × 8) тестів. зображення яблук, враховуючи К-згортання з K = 5 для 120 (3 × 40) доступних зображень.

Фанг та інші в своїй статті [9], зосередились на плоских металевих матеріалах із подібними вимогами до контролю якості, і вона є першою, яка всебічно узагальнює методи виявлення дефектів з двовимірного та тривимірного аспектів. Введено та узагальнено методи навчання, теоретичне обговорення та розвиток застосування виявлення поверхневих дефектів промислових металевих плоских матеріалів. Ця стаття узагальнює результати досліджень автоматизованого візуального виявлення дефектів металевих пластин і смугових поверхонь за останні 30 років, більшість з яких були опубліковані за останні 10 років. Оскільки дослідники проводять експерименти з різними методами на різних наборах даних, важко порівняти ефективність виявлення різних технологій.

### ФОРМУЛЮВАННЯ ЦІЛЕЙ СТАТТІ

**Метою даної роботи** - дослідити та представити результати розпізнавання дефектів виробів органічного походження трубчастої форми засобами нейронних мереж.

## ВИКЛАД ОСНОВНОГО МАТЕРІАЛУ

Одним з найважливіших етапів створення програмного забезпечення для автоматизованої системи контролю та керування якістю виробів органічного походження трубчастої форми є вибір архітектури нейронної мережі, адже від цього залежать точність роботи системи контролю якості виробів та час обробки зображень, що в свою чергу впливає на загальний виробничий цикл виготовлення продукції. Переднавчені нейронні мережі можуть бути корисними для роботи з комплексними зображеннями під час контролю якості продукції, оскільки вони допомагають вирішити проблему нестачі анотованих даних для навчання моделей з нуля. Потрібно розглядати архітектури, які спеціалізуються на обробці зображень. Враховуючи специфіку поставленої задачі, необхідно обрати архітектуру, яка буде базуватись на класифікації зображень. Найбільш оптимальним варіантом будуть саме згорткові нейронні мережі (CNN), оскільки вони здатні виявляти локальні ознаки та патерни на зображеннях, адже вони спеціально розроблені для вирішення задач обробки зображень. Згорткові шари нейронних мереж можуть автоматично вивчати локальні ознаки на зображеннях, такі як форми, кольори та текстури, що є важливими критеріями при вирішенні задач і класифікації і детектування [10].

Вибір конкретної архітектури нейронної мережі потрібно робити на основі наступних параметрів: доступні обчислювальні ресурси, складність поставленої задачі та розмірів даних, які будуть оброблятися нейронною мережею.

Проведемо аналіз існуючих архітектур нейронних мереж, що широко використовуються для вирішення задач комп'ютерного зору та які можна використати для вирішення задач контролю та керування якістю виробів.

Однією з найбільш поширених та ефективних архітектур для вирішення багатьох завдань з обробки зображень є ResNet (Residual Neural Network). Дана архітектура завдяки додаванню скорочених з'єднань дозволяє запобігти виникненню проблеми зниклого градієнту, завдяки чому є можливість побудувати глибоку мережу, яка досягне високої продуктивності. При цьому, архітектури ResNet мають відносно складну реалізацію та потребують великого об'єму даних для навчання нейронної мережі, що можна назвати одним з недоліків даної архітектури. [11]

Варто зауважити, що все ж архітектура ResNet буде більш ефективною при вирішенні задач класифікації і не є вдалим рішенням коли необхідно детектувати та розпізнати дефекти виробу органічного походження коли на одиниці площі може бути відразу декілька класів дефектів, наприклад тріщини, пігментація та сколи після порізки матеріалу для очеретяних трубок.

YOLO (You Only Look Once) — це тип згорткової нейронної мережі, розробленої для задачі детектування об'єктів на зображеннях у реальному часі. Основними особливості YOLO є одноетапний підхід, а саме на відміну від традиційних методів, які спочатку виділяють регіони інтересу, а потім класифікують їх, YOLO обробляє зображення за один раз і це дозволяє досягти високої швидкості. Також зображення розбивається на сітку (наприклад, 7x7), де кожен осередок відповідає за виявлення об'єктів, які його центрують. Кожен осередок генерує прогнози для об'єктів, їх класів і координат. Це швидка та ефективна архітектура для великих наборів даних, яка робить прогнози обробивши фотографію лише один раз, що значно прискорює роботу. [12-13] На рис. 1 представлено типову структуру мережі YOLO [14].

Як було вже зазначено об'єктом контролю було розглянуто вироби органічного походження трубчастої форми, а саме очеретяні трубочки для напоїв рис. 2.



Рис. 1. Типова архітектура YOLO

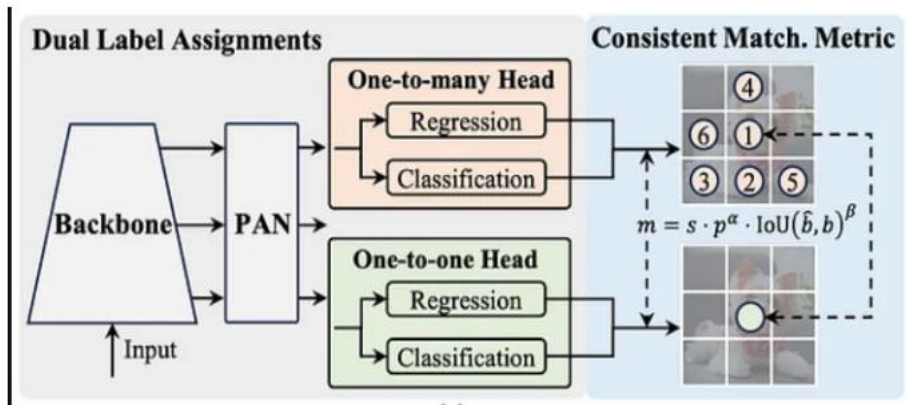


Рис. 2. Очеретяні трубочки для напоїв

Як видно з рисунка 2 очеретяні трубочки мають різний відтінок кольору, різну форму та розміри перерізу, що обумовлено їх органічним походженням і це потребує контролю та сортування виробів на одному із завершальних етапів виробництва. Окрім того на виробках є різні дефекти як внутрішні так і зовнішні, як виправні та і невивправні, які необхідно відбракувати.

Для вирішення цього завдання було запропоновано використати розроблену класифікацію дефектів.

Результат сортування об'єктів можна розділити на п'ять класів [15]:

1. Пігментація (явний, виправний; малозначний; поверхневий дефект) потребує повторної хімічної обробки.
2. Тріщини (Явний, невивправний; Значний; Поверхневий дефект) - брак.
3. Отвори в бокових стінках очеретяної трубки. (явний, невивправний, поверхневий, об'ємний дефект) - брак.
4. Наявність плівки всередині (явний, невивправний, малозначний, об'ємний дефект) потребує механічного доопрацювання.
5. Дефекти порізки (сколи торців) . Явний, невивправний; критичний; поверхневий дефект – брак.

### Характеристики набору даних

#### Dataset Split

Train Set 2838 Images (946\*3)

Valid Set 190 Images

Test Set 125 Images

Total 3153 Images (1261 unique)

#### Classes

dirty 1,397 Images

break 576 Images

hole 330 Images

plivka 166 Images

cut 140 Images

#### Augmentations

Outputs per training example: 3

Flip: Horizontal, Vertical

Shear:  $\pm 5^\circ$  Horizontal,  $\pm 15^\circ$  Vertical

Saturation: Between -30% and +30%

Brightness: Between -15% and +15%

Exposure: Between -10% and +10%

Blur: Up to 3.5px

Розглянемо результати дослідження локалізації та класифікації дефектів виробів засобами нейронних мереж для обраних архітектур YOLOv10s та YOLOv10m. Результати навчання наведені нижче.

### Результати навчання YOLOv10s

45 epochs

YOLOv10s summary (fused): 383 layers, 20418862 parameters, 98.0 GFLOPs

Class	Instances	Box (P	R	mAP50	mAP50-95)
all	388	0.58	0.560	0.573	0.261
break	79	0.445	0.430	0.427	0.148
cut	18	0.749	0.833	0.874	0.500
dirty	207	0.541	0.391	0.466	0.284
hole	61	0.612	0.492	0.514	0.150
plivka	23	0.556	0.652	0.586	0.221

Speed: 0.1ms preprocess, 7.7ms inference, 0.0ms loss, 0.2ms postprocess per image

Матриця помилок та графіки навчання представлені на рис. 3,4.




Рис. 3. Матриця помилок та графіки навчання YOLOv10s

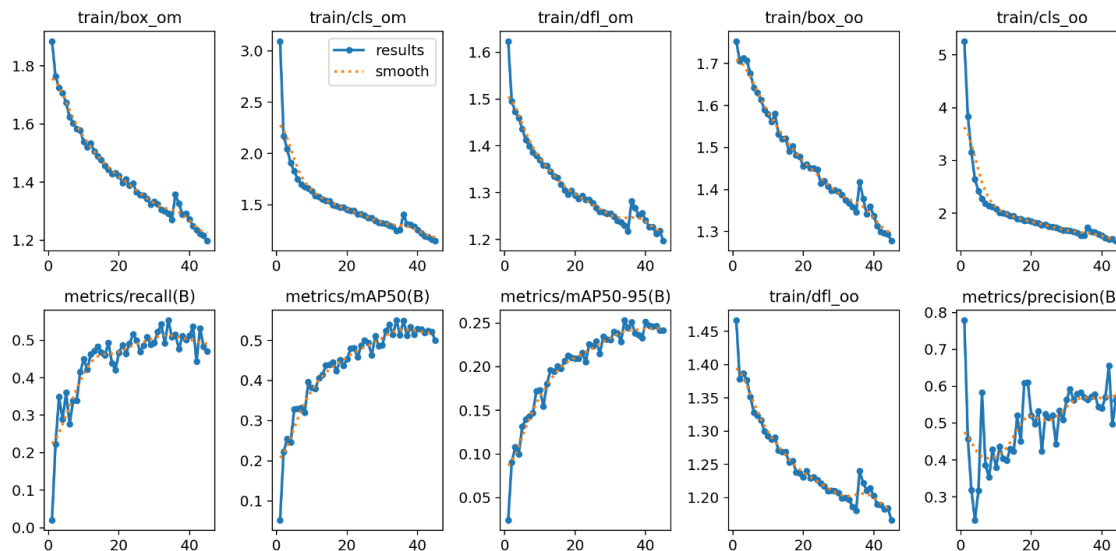


Рис. 4. Метрики навчання

де, **box\_om** - Box Objectness Metric. Це метрика, яка оцінює, наскільки добре модель прогнозує наявність об'єкта в рамці (bounding box). Об'єктність — це впевненість моделі в тому, що в рамці є об'єкт.

**cls\_om** - Class Objectness Metric (можливо Classification Objectness Metric). Це метрика, яка оцінює точність класифікації об'єкта, що знаходиться в рамці.

**dfl\_om** - Distribution Focal Loss Objectness Metric. Це метрика, пов'язана зі статистичним законом розподілу фокальної функції втрат (Focal Loss) для об'єктності.

**box\_oo** - Box Objectness Optimization. Це метрика, яка використовується для оптимізації об'єктності рамки.

**cls\_oo** - Class Objectness Optimization. Це метрика, яка використовується для оптимізації класифікації об'єктів.

**dfl\_oo** - Distribution Focal Loss Optimization. Це метрика, яка використовується для оптимізації закону розподілу Focal Loss.

#### **mAP50**

Mean Average Precision at IoU=0.50.

mAP50 означає середню точність (average precision, AP) при порозі Intersection over Union (IoU) рівному 0.50.

**IoU** — це метрика, що вимірює перекриття між передбаченим рамкою (bounding box) та справжньою рамкою (ground truth box). IoU визначається як площа перетину поділена на площу об'єднання двох рамок.

**AP** розраховується як середнє значення точності (precision) для різних значень recall. mAP (mean AP) — це середнє значення AP для всіх класів.

**mAP50** вказує на те, що для об'єкт вважається правильно детектованим, якщо  $\text{IoU} \geq 0.50$ .

#### **mAP50-95**

Mean Average Precision from IoU=0.50 to IoU=0.95.

mAP50-95 означає середню точність при порогах IoU від 0.50 до 0.95 з кроком 0.05.

Ця метрика більш строга та дає краще уявлення про загальну продуктивність моделі, оскільки враховує різні рівні перекриття.

mAP50-95 розраховується як середнє значення AP для IoU на рівнях 0.50, 0.55, 0.60, ..., 0.95.

На рисунку 5 представлено приклад детектування дефекту типу тріщина.




Рис. 5. Дефект типу «break»

Як видно з рисунка 5 нижній дефект виділяється чітко, верхній – важко помітний навіть людині (зображення з навчального набору даних)

### Результати навчання YOLOv10m

45 epochs

YOLOv10m summary (fused): 369 layers, 16537854 parameters, 61.8 GFLOPs

Class	Instances	Box (P	R	mAP50	mAP50-95)
all	388	0.611	0.581	0.583	0.271
break	79	0.539	0.43	0.422	0.139
cut	18	0.812	0.944	0.936	0.528
dirty	207	0.562	0.444	0.471	0.272
hole	61	0.638	0.52	0.5	0.168
plivka	23	0.504	0.565	0.586	0.25

Speed: 0.1ms preprocess, 5.8ms inference, 0.0ms loss, 0.2ms postprocess per image

Матриця помилок та графіки навчання представлені на рис. 6.




Рис. 6. Матриця помилок та графіки навчання YOLOv10m

Розглянемо приклади детектування дефектів нейронною мережею для кожного з визначених раніше класів таких як плівка, тріщини і півка, що знаходяться поруч та тріщини довгої витягнутої форми рис. 7, 8, 9.



Рис. 7. Дефект типу «hole»




Рис. 8. Дефект типу «break» і «hole» які знаходяться поряд





Рис. 9. Дефекти типу «break» які мають витягнуту форму

### ВИСНОВКИ З ДАНОГО ДОСЛІДЖЕННЯ І ПЕРСПЕКТИВИ ПОДАЛЬШИХ РОЗВІДОК У ДАНОМУ НАПРЯМІ

У роботі було проаналізовано сучасні можливості виявлення поверхневих дефектів виробів. Розглянуто вироби органічного походження для яких локалізація та класифікація дефектів є ускладненою внаслідок їх природньої структури і унікальності. Для вирішення цього завдання вперше було запропоновано використання нейронних мереж декількох архітектур YOLO. В результаті дослідження було представлено результати навчання двох модифікацій нейронної мережі YOLOv10s та YOLOv10m, які були позитивними. Складність такого детектування здебільшого відображалась у неспроможності нейронної мережі локалізувати дефекти довгої протяжної форми і такі дефекти сегментувались нейронною мережею в окремі прямокутні рамки. Проте результати навчання можна покращити за рахунок збільшення об'єму та репрезентативності навчального набору даних. В перспективі подальших досліджень можна розглянути можливість модифікації моделей нейронної мережі Yolo, які мають враховувати можливість розпізнавання дефектів протяжної форми. А також для вирішення завдання ефективного розпізнавання дефектів виробів органічного походження необхідно виконати дослідження пов'язане із застосуванням інших нейромережових детекторів в результаті чого планується отримати інші результати та порівняти їх обравши найоптимальнішу архітектуру за параметром достовірності розпізнавання mAP.

#### Література

1. N. Stelmakh, I. Mastenko, O. Sulima, & T. Rudyk, “Features of the implementation of computer vision in the problems of automated product quality control”, *Informatyka, Automatyka, Pomiary W Gospodarce I Ochronie Środowiska*, 2023. 13(1), pp. 38-41, DOI: 10.35784/iapgos.3434
2. Ковалюк, Д. О., Ковалюк, О. О., & Малішевський, В. С. (2024). Реалізація систем контролю якості продукції на основі машинного зору та web-технологій. *Вісник НТУУ “КПІ імені Ігоря Сікорського”*. Серія: Хімічна інженерія, екологія та ресурсозбереження, (1), 28–34. <https://doi.org/10.20535/2617-9741.1.2024.300980>
3. Guo Y. et al.: Rotational projection statistics for 3D local surface description and object recognition. *International journal of computer vision* 105(1), 2013, 63–86.

4. Johnson A. E.: Spin-images: a representation for 3-D surface matching: Diss. Andrew Edie Johnson – Pittsburgh, Pennsylvania, 1997.
5. Hussein N. Al-Jubori1 and Izzat Al-Darrajil, Tools and Process of Defect Detection in Automated Manufacturing Systems. EAI Endorsed Transactions on Scalable Information Systems, pp 1-7. doi: 10.4108/eetsis.4000
6. Steshenko, Y., Momot A., Protasov A., Muraviov O. (2023) Automation of the process of segmentation of images of metal surface defects using the neural network U-Net. Tekh. Diahnost. ta Neruiniv. Kontrol, 2, 34-40 [in Ukrainian]. <https://doi.org/10.37434/tdnk2023.02.05>
7. Momot A. Automated defect detection in printed circuit boards based on the YOLOv5 neural network / A. Momot, V. Kretsul, O. Muraviov, R. Galagan. // The Paton Welding Journal. – 2024. – №4. – pp. 46–52. DOI: <https://doi.org/10.37434/tpwj2024.04.07>
8. Moallem, P., Serajoddin, A., Pourghassem, H., 2017. Computer vision-based apple grading for golden delicious apples based on surface features. Inf. Process. Agric. 4 (1), 33–40
9. Fang, X., Luo, Q., Zhou, B., Li, C., Tian, L. (2020). Research progress of automated visual surface defect detection for industrial metal planar materials. Sensors, 20(18), 5136. DOI 10.3390/s20185136
10. Alzubaidi, Laith, et al. "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions." Journal of big Data 8 (2021): 1-74.
11. McNeely-White, David, J. Ross Beveridge, and Bruce A. Draper. "Inception and ResNet features are (almost) equivalent." Cognitive Systems Research 59 (2020): 312-318.
12. Redmon J. et al. "You only look once: Unified, real-time object detection", Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 779-788, 2016.
13. Zaidi, S.S., Ansari, M., Aslam, A. et al. (2022) A survey of modern deep learning based object detection models. Digital Signal Processing, 126, 103514. <https://doi.org/10.1016/j.dsp.2022.103514>
14. Jiang, P., Ergu, D., Liu, F. et al. (2022) A review of YOLO algorithm developments. Procedia Computer Sci., 199, 1066- 1073. <https://doi.org/10.1016/j.procs.2022.01.135>
15. Stelmakh N.V. Mastenko I.V. Classification and detection of defects in tubular products using machine vision. Вчені записки ТНУ імені В.І. Вернадського. Серія: Технічні науки. Том 35 (74) № 2 2024. с. 167-172. DOI <https://doi.org/10.32782/2663-5941/2024.2/23>

#### References

1. N. Stelmakh, I. Mastenko, O. Sulima, & T. Rudyk, "Features of the implementation of computer vision in the problems of automated product quality control", Informatyka, Automatyka, Pomiar W Gospodarce I Ochronie Środowiska, 2023. 13(1), pp. 38-41, DOI: 10.35784/iapgos.3434
2. Kovalyuk, D.O., Kovalyuk, O.O. i Malishevs'kyy, V.S. 2024. Realizatsiya system kontrolyu yakosti produktsiyi na osnovi mashynnoho zoru ta web-tekhnologiy. Visnyk NTUU "KPI imeni Ihorya Sikors'koho". Seriya: Khimichna inzheneriya, ekolohiya ta resursozberezhennya. 1 (Ber 2024), 28–34. <https://doi.org/10.20535/2617-9741.1.2024.300980>
3. Guo Y. et al.: Rotational projection statistics for 3D local surface description and object recognition. International journal of computer vision 105(1), 2013, 63–86.
4. Johnson A. E.: Spin-images: a representation for 3-D surface matching: Diss. Andrew Edie Johnson – Pittsburgh, Pennsylvania, 1997.
5. Hussein N. Al-Jubori1 and Izzat Al-Darrajil, Tools and Process of Defect Detection in Automated Manufacturing Systems. EAI Endorsed Transactions on Scalable Information Systems, pp 1-7. doi: 10.4108/eetsis.4000
6. Steshenko, Y., Momot A., Protasov A., Muraviov O. (2023) Automation of the process of segmentation of images of metal surface defects using the neural network U-Net. Tekh. Diahnost. ta Neruiniv. Kontrol, 2, 34-40 [in Ukrainian]. <https://doi.org/10.37434/tdnk2023.02.05>
7. Momot A. Automated defect detection in printed circuit boards based on the YOLOv5 neural network / A. Momot, V. Kretsul, O. Muraviov, R. Galagan. // The Paton Welding Journal. – 2024. – №4. – pp. 46–52. DOI: <https://doi.org/10.37434/tpwj2024.04.07>
8. Moallem, P., Serajoddin, A., Pourghassem, H., 2017. Computer vision-based apple grading for golden delicious apples based on surface features. Inf. Process. Agric. 4 (1), 33–40
9. Fang, X., Luo, Q., Zhou, B., Li, C., Tian, L. (2020). Research progress of automated visual surface defect detection for industrial metal planar materials. Sensors, 20(18), 5136. DOI 10.3390/s20185136
10. Alzubaidi, Laith, et al. "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions." Journal of big Data 8 (2021): 1-74.
11. McNeely-White, David, J. Ross Beveridge, and Bruce A. Draper. "Inception and ResNet features are (almost) equivalent." Cognitive Systems Research 59 (2020): 312-318.
12. Redmon J. et al. "You only look once: Unified, real-time object detection", Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 779-788, 2016.
13. Zaidi, S.S., Ansari, M., Aslam, A. et al. (2022) A survey of modern deep learning based object detection models. Digital Signal Processing, 126, 103514. <https://doi.org/10.1016/j.dsp.2022.103514>
14. Jiang, P., Ergu, D., Liu, F. et al. (2022) A review of YOLO algorithm developments. Procedia Computer Sci., 199, 1066- 1073. <https://doi.org/10.1016/j.procs.2022.01.135>
15. Stelmakh N.V. Mastenko I.V. Classification and detection of defects in tubular products using machine vision. Вчені записки ТНУ імені В.І. Вернадського. Серія: Технічні науки. Том 35 (74) № 2 2024. с. 167-172. <https://doi.org/10.32782/2663-5941/2024.2/23>