

УДК 510

DOI [https://doi.org/10.24144/2616-7700.2022.41\(2\).141-150](https://doi.org/10.24144/2616-7700.2022.41(2).141-150)**М. В. Роботишин¹, М. М. Маляр²**

¹ ДВНЗ «Ужгородський національний університет»,
аспірант кафедри кібернетики і прикладної математики,
mykola.robotyshyn@uzhnu.edu.ua
ORCID: <https://orcid.org/0000-0001-6567-6974>

² ДВНЗ «Ужгородський національний університет»,
професор кафедри кібернетики і прикладної математики,
доктор технічних наук
mykola.malyar@uzhnu.edu.ua
ORCID: <https://orcid.org/0000-0002-2544-1959>

АНАЛІЗ ДЕЯКИХ МЕТОДІВ РОЗВ'ЯЗАННЯ ЗАДАЧІ РОЗПІЗНАВАННЯ ДЕФЕКТІВ НА ЗОБРАЖЕННЯХ

Задача розпізнавання дефектів користується широкою популярністю, особливо її застосування на індустріальних заводах, де об'єкти виготовляються десятками тисячами на день та можуть містити дефекти. Об'єкти з дефектами потрібно відділити від загальної маси об'єктів, для того щоб фінальний споживач отримав як найякісніший товар. Але перш ніж відділити дефектні об'єкти, їх потрібно знайти, отже розпізнати.

У даній роботі проаналізовано найпопулярніші методи для розв'язання задачі розпізнавання дефектів, коли вхідні дані є зображення. Розглянуто застосування як існуючих автоматизованих рішень, так і застосування методів на основі згорткових нейромереж, а саме нейронні мережі сегментації та детекції, які користуються широкою популярністю наразі. Проведено огляд даних методів та зроблено порівняльний аналіз різних класів методів на основі таких факторів як: вимоги до вхідних даних та вимоги до обчислювальних потужностей.

Ключові слова: задача розпізнавання дефектів, конволюційні нейромережі, моделі сегментації та детекції.

1. Вступ. Керування великим бізнесом неможливо уявити без автоматизації. Найчастіше автоматизацію необхідно впроваджувати в процеси, які повторюються з високою частотою та є сталими з точки зору схильностей до критичних змін. До таких процесів можна віднести — процес виготовлення об'єктів на індустріальному виробництві. Зазвичай даний процес складається з багатьох підпроцесів і один з них — це інспекція об'єкта на наявність дефектів та подальше сортування у разі виявлення одного чи декількох дефектів.

Процес інспекції об'єкта на наявність дефектів може бути зроблений ручним/мануальним або автоматизованим способами. Очевидно, що ручний спосіб є обмежений, оскільки вимагає велику кількість задіяних людей та їх домену експертизу для виявлення дефектів. В основі автоматизованих способів лежать інтелектуальні методи аналізу зображень, отриманих з камер. Враховуючи сучасний розвиток камер зробити знімок, на якому буде чітко видно дефекти є цілком реальною задачею. З часом кожне велике підприємство набуває стану коли кількість об'єктів, що вони виготовляють є непосильне для ручного способу інспекції. З іншої сторони впровадження автоматичного способу не є тривіальним та вимагає відповіді на багато запитань:

- Яку технологію (методи) вибрати для розпізнавання дефектів?
- Наскільки якісно технологія буде відділяти дефектні об'єкти?

- Як її інтегрувати у виробництво?
- Як її підтримувати надалі?

Цей перелік можна продовжувати далі, однак так чи інакше відповіді залежать від ключового питання, а саме: “які методи чи групу методів обрати для аналізу зображень на предмет виявлення одного чи декількох дефектів на об’єкті?”. Найбільшою популярністю наразі користуються методи аналізу зображень на основі штучного інтелекту в основі яких лежать нейронні мережі, що можуть навчатися певної логіки на тренувальному промаркованому наборі даних. За допомогою них можна побудувати технологію виявлення дефектів, яка в перспективі дозволить автоматизувати процес інспекції.

Про актуальність даної проблеми найкраще свідчить те, скільки коштів бізнес готовий вкладати в її дослідження. Отже, згідно [1] ринок автоматизованих систем виявлення дефектів на основі методів нейронних мереж зростає до 5 млрд дол. в 2025 році. Популярні сфери застосування наступні: виявлення дефектів на інтегральних схемах, материнських платах, зарядних електробатарей, виявлення тріщин на металевих пластинах, мобільних екранах, порізи на хутряних виробах, подряпини на дерев’яних матеріалах, дефекти в бамбукових/очеретяних трубках і т.д. ... Головні недоліки в мануальних системах виявлення дефектів наведено в дослідженні McKinsey & Company [2]. Основні з них це: помилка при ручній перевірці об’єкта людиною коливається в межах 20-30% (зазвичай спричинена такими факторами як втома та неухважність) та обмеження в максимально можливій кількості об’єктів, що можуть бути перевірені за одиницю часу. В той же час більше 60% респондентів сказали, що після застосування автоматизованих систем вони змогли покращити точність розпізнавання дефектів та проблеми з масштабуванням. Згідно цього ж дослідження більше 50% інвесторів оптимістично ставляться до вкладання коштів в дослідження можливості застосувати такі системи у себе на виробництві. Також тільки 15% респондентів вважають за краще купити off-the-shelf технології, що демонструє необхідність працювати над розробкою таких систем з нуля на відміну від використання вже існуючих рішень таких як Omron, Cogniac, ZEISS.

Важливо відмітити, що аналіз методів у даній роботі проводиться з припущенням, що дані методи будуть застосовані до такого типу дефектів як: візуальні дефекти на поверхні площини об’єкта. Тобто, дефекти можуть бути виявлені людським оком, без потреби в дотику до самого об’єкта.

У даній роботі проаналізовано найпопулярніші методи для задачі розпізнавання дефектів на основі зображень. Аналіз зосереджено на методах на основі глибокого навчання нейронних мереж. На думку авторів, за допомогою останніх можна побудувати технологію виявлення дефектів, яка в перспективі дозволить автоматизувати процес інспекції та покращити ключові, наведені вище, недоліки, що існують в мануальних системах.

2. Класи можливих методів виявлення дефектів. Методи для розв’язання задачі розпізнавання дефектів базуються на інтелектуальному аналізі вхідних зображень. Більш загальна назва — це методи комп’ютерного зору (computer vision). Дана дисципліна пройшла довгий шлях, починаючи від традиційних методів комп’ютерного зору до методів сьогодення, що використовують процес глибокого навчання згорткових нейронних мереж. Існує багато різних методів та їх класів, але дана стаття сфокусована на аналізі методів

глибокого навчання, таких як: нейромережі сегментації та детекції об'єктів. А також їх порівняння з традиційними алгоритмами в контексті вимог до вхідних даних, щоб застосувати алгоритм та обчислювальних потужностей, необхідних для проведення процесу навчання та аналізу зображень.

Процес навчання нейромережі, архітектура якої складається з багатьох шарів, де кожний шар містить ряд операцій з згортковими фільтрами, за допомогою алгоритму *back-propagation* набув терміну *глибинне навчання* (*deep learning*). Застосування глибокого навчання для аналізу зображень — це одна з найпопулярніших та найперспективніших сфер застосування нейронних мереж. Детальний аналіз становлення та розвитку цієї сфери, а також огляд всіх існуючих методів разом з означеннями найбільш фундаментальних понять викладено в [3,4,5,6]. Для задачі розпізнавання дефектів найбільш підходящими методами є: сегментаційні та детекційні нейромережі (*segmentation and detection neural networks*). Одна з основних причин полягає в тому, що для задачі визначення дефектів необхідно не просто сказати, що “зображення об'єкту A містить дефект”, а потрібно також вказати де саме на зображенні є дефектна зона.

3. Вхідні та вихідні дані. Нейромережі (моделі) сегментації та детекції мають багато спільного. Для того щоб навчити їх потрібно тренувальний набір даних. Один об'єкт тренувального набору даних складається з вхідного зображення та промаркованого дефектного регіону. Для задачі сегментації дефектний регіон може бути представлений у вигляді матриці розмірність якої співпадає з вхідним зображенням. Кожний елемент матриці може набувати значень із діапазону $[0, k]$, де $k \in Z$ — кількість можливих класів дефектів. Якщо елемент матриці має значення 0 — регіон не дефектний, а якщо значення дорівнює в межах $[0, k]$, то регіон має дефект відповідного класу. Тобто, моделі сегментації вимагають наявності промаркованих даних на рівні кожного пікселя, що є одночасно і перевагою і недоліком. Перевага в тому, що дефекти промарковані на найбільш детальному рівні — пікселю, що дає найповнішу інформацію про дефектну зону зображення. Очевидний недолік — це кількість затраченого часу, який необхідно для маркування кожного зображення. З точки зору необхідних вхідних даних, нейромережі детекції відрізняються тим, що достатньо промаркувати регіон у вигляді прямокутника (*bounding box*), що з одної сторони є швидшим процесом, але з іншої втрачається певна інформація, оскільки в прямокутнику можуть міститися як дефектні так і не дефектні пікселі. Для задачі детекції приклад вхідних даних відрізняється від сегментації тим, що нам не потрібно вказувати всю матрицю, а потрібно надати тільки інформацію, де розташований об'єкт (дефектна зона) у форматі $[x_{min}, y_{min}, x_{max}, y_{max}, p]$, де перші 4 елементи — це координати прямокутника, який визначає дефектний регіон, p — індекс відповідного дефектного класу. Кількість зон довільна, тобто зображення як може взагалі не містити дефектної зони, так і містити декілька.

Приклад вхідних даних для нейромереж сегментації та детекції зображено на рис. 1. Всі пікселі, які всередині жовтого регіону є дефектними. На основі даного промаркованого зображення легко створити необхідну вхідну промарковану матрицю, про яку описано вище. Також варто відмітити, що теоретично сегментаційний підхід буде працювати навіть якщо дані будуть промарковані у форматі для моделей детекції. Але якість роботи моделі у такому випадку



а. Дефектні зони промарковані полігоном на максимально наближеному рівні до пікселю



б. Одна дефектна зона, яка промарковані одним прямокутником (bounding box)

Рис. 1. Приклад маркування дефектних зон для сегментації (а) та детекції (б).

може викликати запитання та потребує детального аналізу. Зазвичай, тренувальний набір даних повинний складатися з декількох сотень екземплярів, де один екземпляр — це вхідне зображення разом з матрицею дефектних регіонів.

Вихідні дані, тобто результати роботи сегментаційної моделі — це ймовірність пікселя набути значення одного чи іншого класу. Математично, якщо у нас є k класів, то результатом буде k матриць, де кожна матриця відповідає за один клас. Відповідно значення кожного пікселя можна представити у вигляді масиву ймовірностей $[p_0, p_1, p_2, \dots, p_k]$, які сумарно повинні дорівнювати 1. Тобто, якщо для кожного пікселя ми візьмемо максимальне значення ймовірностей класів і запишемо відповідний індекс класу у матрицю, то отримаємо таку саму матрицю, як і вхідна матриця дефектів. Тільки тепер кожний піксель — це клас дефекту, визначений алгоритмічно, а не за допомогою ручної розмітки людиною. Таку вихідну матрицю класів прийнято називати “маскою”. Для моделей детекції результати зображені у вигляді масиву $[x_{min}, y_{min}, x_{max}, y_{max}, cl, p]$, де перші 4 елементи — це координати прямокутника (bounding box), який визначає дефектний регіон, cl — індекс відповідного класу з ймовірністю p .

Обидва підходи в результаті видають не просто клас об’єкта, а і його ймовірність, що дозволяє знайти оптимальний поріг (threshold) ймовірності. За допомогою нього, можна маніпулювати результатами та пристосувати їх краще до своєї доменної задачі. Наприклад, якщо ціна помилки дуже висока, то ми можемо встановити поріг ймовірності в 90% і казати, що дефектна зона є справді дефектною тільки тоді коли ймовірність $\geq threshold$ величини.

4. Огляд найпопулярніших нейромереж сегментації та детекції. Важливо відмітити, що незважаючи на схожість необхідних вхідних даних, самі нейромережі сегментації та детекції є різними з точки зору архітектури (кількість шарів та згорткових фільтрів, активуючі функції ...) та процесу навчання. В основі моделей детекції об’єкта відбувається процес обробки зображення на рівні координат об’єкта, тобто, на рівні bounding box. В той час як в сегмен-

таційних моделей даний процес є на більш деталізованому рівні — пікселю.

Довгий час найпопулярнішими нейронними мережами детекції були методи сімейства R-CNN (Region Based Convolutional Neural Network): R-CNN, Fast R-CNN, Faster R-CNN. Головна ідея полягала в тому, що генерувалися певні регіони (прямокутники) зображення, так-звані, “кандидати” за допомогою методу кластеризації *selective search*. Потім ці кандидати за допомогою типової CNN порівнювалися з промаркованими вхідними даними на схожість. Найбільш схожі об’єкти і були результатом роботи нейромережі. Тобто, процес складався з двох ключових кроків: генерація кандидатів та їх аналіз з метою вибрати найбільш схожі до об’єктів, які ми шукаємо на зображенні. Еволюція цих методів полягала спочатку в оптимізації кількості кандидатів для пришвидшення обчислень (в першій версії R-CNN було 2000 кандидатів), а далі в заміні методу *selective search* на окрему CNN для більш якісної генерації кандидатів, що й було досягнуто в версії Faster R-CNN. Очевидно є два головні недоліки даних методів: повільна швидкість детекції (оскільки потрібно проаналізувати кожний згенерований регіон) та власне сам факт, що, якщо на першому кроці не буде згенеровано точного кандидата, подальший процес порівняння втрачає сенс. Модифікованою версією даних методів є метод YOLO (You Only Look Once) — що дослівно означає “ти дивишся тільки один раз” з відсилкою до попередніх методів, які мали дві окремі нейромережі для генерації кандидатів та їх подальший аналіз. Даний метод робить все в одному кроці і генерує об’єкти і аналізує їх, що безперечно дає йому перевагу в швидкості. Так само як і попередні методи, даний метод еволюціонує з часом, на момент написання статті вже існує версія *yolov7*, тобто сьома модифікація алгоритму. Звичайно, найбільш повну інформацію про дані нейромережі можна отримати в загальновідомих оригінальних статтях. Також в [7] наведено додатковий аналіз даних методів та візуалізація їх архітектур, що дає краще розуміння, як вони працюють.

На відміну від попередніх методів, методи сегментації важко розділити на окремі загальні класи. Що можна стверджувати, це те, що існує два типи сегментації: *instance* та *semantic*. Різниця між ними наступна: якщо ми знайшли декілька дефектів класу A і не розрізняємо їх між собою (тобто, нам достатньо знати їх клас), то це є *semantic segmentation*. А якщо нам потрібно ще розрізняти їх між собою, типу дефект класу A (1), дефект класу A (2), ... — *instance segmentation*. На практиці, однозначно *semantic* є більш вживаною, тому що зазвичай нам не потрібно розрізняти між собою дефекти одного класу, нам достатньо сказати, що вони належать до цього класу. А чи різні вони між собою чи ні — це не обов’язково. Так чи інакше всі методи сегментації в *deep learning* пов’язані з згортковими нейронними мережами. Одним із найпопулярніших методів є U-Net. Дана модель вперше застосовувалася для задачі знаходження ракових пухлин на основі зображень легенів та мозку. Її U-подібна архітектура спочатку зменшує розмірність вхідного зображення (*down-sampling*) за допомогою конволюційних (згорткових) фільтрів та знаходить регіони зображення (*feature map*), що містять найважливішу інформацію. Далі відбувається процедура *up-sampling*, тобто повернення до оригінальних розмірів зображення. Особливість архітектури в тому, що є взаємодія між кожним шаром *down* та *up* семплінгу, що дозволяє повернути зображення до оригінального вигляду без втрати будь-якої інформації, ще й плюс до того зберегти інформацію, знайдену

при процедурі down-sampling, тобто у нашому випадку дефектну зону. Існує ряд інших методів, таких як: DeepLab, FPN, LinkNet та інші. Детальний огляд даних методів наведено в [8].




Рис. 2. U-подібна архітектура сегментаційної моделі U-Net.

Одним із популярних напрямків розвитку моделей сегментації та детекції є комбіновані моделі, які дозволяють представити фінальний результат одночасно як за допомогою сегментаційної маски так і за допомогою регіону (bounding box) об'єкта. А далі в залежності від рівня деталізації можна використовувати один чи інший вид представлення результатів. Найвідоміші комбіновані архітектури це: Mask R-CNN та yolov7. Також інший тренд розвитку даних методів полягає в застосуванні ідеї трансформерів (transformers) [9], що набули широкої популярності в методах обробки природньої мови та активно наразі застосовуються для задач обробки зображень.

Всі методи, що наведені в даному розділі є відносно новими. Найстаріший з них — це метод детекції R-CNN (2014 р.), а найновіший — yolov7 (2022 р.). Очевидно, що дана сфера еволюціонує дуже швидко, з'являються нові модифікації існуючих алгоритмів. На думку авторів, глобальний тренд розвитку даних підходів полягає в оптимізації швидкості роботи для ефективного їх застосування на мобільних пристроях та різних контролерах, що можуть бути вбудовані безпосередньо в камеру чи інші механізми. Також варто відзначити, що не можна сказати що одна нейронна мережа є суттєво краща чи гірша за іншу. В основному все більше залежить від якості та кількості необхідних промаркованих вхідних даних, ніж вибір самої архітектури.

5. Порівняльний аналіз різних методів з точки зору практичного застосування. Головною метою даного розділу є порівняльний аналіз мето-

дів глибинного навчання (deep learning), традиційних методів комп'ютерного зору та існуючих автоматизованих рішень для розв'язання задачі розпізнавання дефектів. З точки зору практичного застосування головними критеріями порівняння є вимоги до вхідних даних, необхідні обчислювальні потужності та орієнтовний рівень точності розпізнавання.

Під традиційними методами комп'ютерного зору будемо мати на увазі наступні методи: методи порогування (thresholding), методи виявлення контурів (edge detection), методи розростання областей, методи засновані на диференціальних рівняннях з частинними похідними та інші [10]. Дані методи відрізняються від нейронних мереж, про які описано в попередньому розділі, тим, що:

1. З точки зору вхідних даних для їх роботи не потрібно наявності промаркованих зображень.
2. З точки зору архітектури моделей, в їх роботі не використовується процес навчання на помилках (back-propagation).
3. З точки зору обчислювальних потужностей, для їх роботи не потрібно відеокарту чи великі потужності.

Під автоматизованими рішеннями будемо мати на увазі рішення, що інтегровані в камеру, не вимагають додаткового комп'ютера для проведення обчислень та дозволяють зробити певні налаштування під доменну задачу. Приклади таких систем для розв'язання задачі розпізнавання дефектів наступні: Omron, Cogniac, ZEISS, EPIC та інші.

В таблиці Табл. 1 наведено порівняльний аналіз різних методів розв'язання задачі розпізнавання дефектів з точки зору необхідних вхідних даних, в Табл. 2 з точки зору необхідних обчислювальних потужностей та архітектури, в Табл. 3 з точки зору затраченого часу та коштів на побудову технології виявлення дефектів.

Таблиця 1.

Порівняльний аналіз вхідних даних

Назва метода	Промарковані вхідні дані	К-сть зображень
Методи глибинного навчання	Так	100+
Традиційні методи	Ні	декілька
Автоматизовані рішення	Ні	декілька

На основі даного аналізу можна зробити порівняння алгоритмів з різної сторони. Метою не є сказати, що краще, а що гірше — тому що це дуже складно визначити і в основній мірі залежить від типу об'єкта з дефектами та складності самих дефектів. Методи глибинного навчання відрізняються від традиційних в тому, що для них потрібно промарковані вхідні дані та обчислювальні потужності. Звичайно, їх точність може бути суттєво вищою, особливо у випадках, коли дефекти є різноманітні та складні для виявлення. Але існують задачі, коли дефекти є очевидні, прості, однакові і для них достатньо застосувати традиційні методи. Альтернативним варіантом до традиційних методів, є автоматизовані

Таблиця 2.

Порівняльний аналіз обчислювальних потужностей та архітектури

Назва метода	Відеокарта для обчислень	Алгоритм навчання
Методи глибинного навчання	Так	Backpropagation
Традиційні методи	Ні	відсутній
Автоматизовані рішення	Ні/Так	ручна корекція

Таблиця 3.

Порівняльний аналіз часу та коштів для впровадження

Назва метода	Швидкість розробки	Кількість коштів
Методи глибинного навчання	Повільно	Середній рівень
Традиційні методи	Швидко	Низький рівень
Автоматизовані рішення	Не вимагає розробки	Високий рівень

рішення. Це і є по факту ті ж алгоритми, але вже з імплементацією та готовністю бути інтегрованим в виробництво. Такі системи є дуже різними, деякі з них навіть застосовують процес перенавчання системи (для покращення точності розпізнавання) за допомогою ручної корекції. Відповідно не потрібно витратити час на побудову технології з нуля, але скоріше за все це коштуватиме значно дорожче. І найголовніше, це дуже ризиковано, тому що незрозуміло як якісно дана система буде працювати на нових, небачених до цього, об'єктах.

Для розв'язання задачі розпізнавання дефектів першим кроком є зрозуміти складність визначення дефекту. Зазвичай, для початку проводиться ручний огляд, який дає відповідь на питання: "Чи можливо визначити дефект людським оком?". Якщо так, то далі потрібно правильно розмістити камеру та почати збирати зображення з дефектними об'єктами. Часто розпочинають розв'язок задачі використовуючи традиційні методи комп'ютерного зору. Це дозволяє встановити мінімальний поріг результату (baseline) з яким надалі будуть порівнюватися методи глибинного навчання. Коли дефектна область є складна та різноманітна однозначно методи глибинного навчання принесуть найкращий результат. В таблиці наведено необхідну кількість зображень в 100+ для тренування першої ітерації алгоритму використовуючи техніку transfer learning — коли ми беремо вже наперед натреновану нейронну мережу та модифікуємо її для нашого набору даних, тобто до нашої задачі. Детальний огляд як побудувати з нуля технологію визначення дефектів на основі методів глибинного навчання наведено в [11].

6. Висновок. У роботі проведено огляд методів глибинного навчання, а саме нейронних мереж сегментації та детекції. Розглянуто приклад вхідних даних та способи їх маркування. Проведено різносторонній порівняльний аналіз наступних класів методів: методи глибинного навчання сегментації та детекції,

традиційні методи комп'ютерного зору та автоматизовані рішення. Наведено аналіз ринку задачі виявлення дефектів за допомогою інтелектуальних методів аналізу зображення.

Список використаної літератури

1. Defect detection market report. URL: <https://www.marketsandmarkets.com/Market-Reports/defect-detection-market-124751233.html> (date of access: 25.09.2022).
2. Machine Vision Survey. URL: <https://landing.ai/wp-content/uploads/2020/11/MachineVisionSurvey.pdf> (date of access: 25.09.2022).
3. Voulodimos A., Doulamis N., Doulamis A., Protopapadakis E. Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*. 2018. DOI: <https://doi.org/10.1155/2018/7068349>
4. Sinha R., Pandey R., Pattnaik R. Deep Learning For Computer Vision Tasks: A review. *International Conference on Intelligent Computing and Control*. 2018.
5. Dargan S., Kumar M., Аyyagari M. R., Kumar G. A survey of deep learning and its applications: a new paradigm to machine learning. *Archives of Computational Methods in Engineering*. 2020. Vol. 27. No. 4. P. 1071–1092.
6. Шаркаді М. М., Роботишин М. В., Мальяр М. М. Моделі і методи машинного навчання для завдань передбачення. *Науковий вісник Ужгородського університету. Серія «Математика і інформатика»*. 2020. Т. 1. № 36. С. 112–122. DOI: [https://doi.org/10.24144/2616-7700.2020.1\(36\).112-122](https://doi.org/10.24144/2616-7700.2020.1(36).112-122)
7. Deep learning architectures. URL: <https://programmatically.com/deep-learning-architectures-for-object-detection-yolo-vs-ssd-vs-rcnn/> (date of access: 21.09.2022).
8. Semantic image segmentation. URL: <https://nanonets.com/blog/semantic-image-segmentation-2020/> (date of access: 31.09.2022).
9. Transformers in computer vision. URL: <https://www.edge-ai-vision.com/2022/05/transformers-in-computer-vision/> (date of access: 31.09.2022).
10. Skoryk A., Chyrka Y., Gorovyi I., Grechnyev O., Vyplavin P. Comparative Analysis of Classic Computer Vision Methods and Deep Convolutional Neural Networks for Floor Segmentation, *2020 IEEE Third International Conference on Data Stream Mining & Processing (DSMP)*. 2020. P. 217–221. DOI: <https://doi.org/10.1109/DSMP47368.2020.9204339>
11. Robotyshyn M., Sharkadi M., Malyar M. Surface defect detection based on deep learning approach. *International Scientific Symposium «Intelligent Solutions»*. 2021. P. 32–44 .

Robotyshyn M. V., Malyar M. M. Analysis of some methods for solving the problem of detecting defect in images.

The problem of defect detection is widely popular, especially its application in industrial plants, where objects are produced in tens of thousands per day and can create defects. Objects with defects must be separated from the total mass of objects in order for the final consumer to receive the largest product. But before separating defective objects, they need to be found, therefore recognized.

This paper analyzes the most popular methods for solving the problem of defect detection when the input data is an image. The use of both existing automated solutions and the use of methods based on convolutional neural networks, namely neural networks of segmentation and detection, which are currently widely popular, are considered. A review of these methods was conducted and a comparative analysis of different classes of methods was made based on such factors as: requirements for input data and requirements for computing power.

Keywords: Surface Defect Detection, Convolutional Neural Networks, Semantic Segmentation and Object Detection.

References

1. Defect detection market report. Retrieved from: <https://www.marketsandmarkets.com/Market-Reports/defect-detection-market-124751233.html>
2. Machine Vision Survey. Retrieved from: <https://landing.ai/wp-content/uploads/2020/11/MachineVisionSurvey.pdf>
3. Voulodimos, A., Doulamis, N., Doulamis, A., & Protopapadakis, E. (2018). Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*, 1–13. <https://doi.org/10.1155/2018/7068349>
4. Sinha, R., Pandey, R., & Pattnaik, R. (2018). Deep Learning For Computer Vision Tasks: A review. *International Conference on Intelligent Computing and Control*.
5. Dargan, S., Kumar, M., Ayyagari, M. R., & Kumar, G. (2020). A survey of deep learning and its applications: a new paradigm to machine learning. *Archives of Computational Methods in Engineering*, 27(4), 1071–1092.
6. Sharkadi, M., Robotyshyn, M., & Malyar, M. (2020). Machine Learning Models and Methods for forecasting problems. *Scientific Bulletin of Uzhhorod University. Series Of Mathematics and Informatics*, 1(36), 112–122. [https://doi.org/10.24144/2616-7700.2020.1\(36\).112-122](https://doi.org/10.24144/2616-7700.2020.1(36).112-122) [in Ukrainian].
7. Deep learning architectures. Retrieved from: <https://programmatically.com/deep-learning-architectures-for-object-detection-yolo-vs-ssd-vs-rcnn/>
8. Semantic image segmentation. Retrieved from: <https://nanonets.com/blog/semantic-image-segmentation-2020/>
9. Transformers in computer vision. Retrieved from: <https://www.edge-ai-vision.com/2022/05/transformers-in-computer-vision/>
10. Skoryk, A., Chyrka, Y., Gorovyi, I., Grechnyev, O., & Vyplavin, P. (2020). Comparative Analysis of Classic Computer Vision Methods and Deep Convolutional Neural Networks for Floor Segmentation, *2020 IEEE Third International Conference on Data Stream Mining & Processing (DSMP)*, 217–221. <https://doi.org/10.1109/DSMP47368.2020.9204339>.
11. Robotyshyn, M., Sharkadi, M., & Malyar, M. (2021). Surface defect detection based on deep learning approach. *International Scientific Symposium «Intelligent Solutions»*, 32–44.

Одержано 15.10.2022