

АВТОМАТИЗОВАНЕ ДЕТЕКТУВАННЯ ДЕФЕКТІВ ДРУКОВАНИХ ПЛАТ НА ОСНОВІ НЕЙРОННОЇ МЕРЕЖІ YOLOV5

А.С. Момот, В.В. Крецул, О.В. Муравйов, Р.М. Галаган

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського». 03056, м. Київ, Берестейський просп., 37. E-mail: drewmomot@gmail.com, asnk@kpi.ua

У роботі розглянуто можливості застосування моделі глибинного навчання YOLOv5s у задачі автоматизації процесу детектування поверхневих дефектів на друкованих платах. Сучасні друковані плати виготовляються у великих обсягах і містять значну кількість елементів. Технологічний процес виготовлення друкованих плат є складним, що підвищує ймовірність виникнення дефектів розведення плати, таких як короткі замикання, розриви, «укуси миші» тощо. Дані дефекти є поверхневими та можуть бути виявлені за допомогою візуально-оптичного контролю. У порівнянні з іншими методами візуально-оптичний легше піддається автоматизації. Доведено, що перспективним є застосування моделей глибинного навчання для автоматизації процесу виявлення об'єктів на зображеннях. Сучасні нейронні мережі можуть автоматично з високою достовірністю детектувати поверхневі дефекти на зображеннях друкованих плат. У статті розглянуто клас моделей YOLO. Встановлено, що модель YOLOv5 має кращі показники швидкодії та достовірності розпізнавання, ніж попередні модифікації. У даному дослідженні реалізовано та навчено модель YOLOv5s для перевірки ефективності роботи даної мережі в задачі автоматизованого детектування поверхневих дефектів друкованих плат. Для навчання використовувався відкритий набір даних «PCB Defects». Проведено якісний та кількісний аналіз ефективності роботи навченої мережі на тестовому наборі даних. Встановлено, що мережа здатна детектувати поверхневі дефекти друкованих плат з достовірністю 92,5 % за показником mAP50. Додатково проаналізовано результати розпізнавання різних класів дефектів і надано рекомендації щодо подальшого вдосконалення системи. Зокрема, перспективним є застосування аугментації навчальних даних і використання складнішої архітектури моделі глибинного навчання. Бібліогр. 15, табл. 2, рис. 4.

Ключові слова: дефекти друкованих плат, детектування об'єктів, глибинне навчання, YOLOv5

Вступ. Автоматизація виробництва електронних модулів є важливою складовою у сучасному виготовленні радіоелектронної апаратури. Забезпечення якості та надійності електронних модулів є ключовим етапом цього процесу, а своєчасне виявлення дефектів є надзвичайно важливим завданням. Наслідком встановлення несправних електронних плат у прилади може стати підвищення загальних витрат на виробництво та сервісне обслуговування радіоелектронної апаратури, а також можливе травмування кінцевого користувача. Тому раннє виявлення дефектів є надзвичайно критичним і має велике значення для забезпечення бездоганної якості та безпеки використання електронних пристроїв.

У сучасних умовах спостерігається тенденція до зменшення розмірів електронних модулів і компонентів для отримання більшої компактності пристроїв, в яких вони будуть використовуватись. Ще одним важливим фактором є значне зростання обсягів виробництва електронних пристроїв. У зв'язку з цим, виникає необхідність використання новітніх методів автоматизації процесу контролю дефектів друкованих плат. З точки зору оптимального поєднання інформативності, швидкодії та простоти автоматизації, одним із найперспек-

тивніших методів виявлення дефектів друкованих плат є візуально-оптичний контроль.

Візуально-оптичний контроль забезпечує можливість виявлення широкого спектру поверхневих дефектів, таких як пошкодження компонентів, неправильне розташування або з'єднання, дефекти паяння та багато інших. Цей метод дозволяє отримувати об'єктивні результати, що зменшує вплив людського фактору. Використання комп'ютерного зору, алгоритмів обробки зображень і машинного навчання дозволяє автоматизувати процес контролю з високою швидкістю та достовірністю [1]. Завдяки цьому метод ефективно використовується у задачах контролю якості друкованих плат навіть за великих обсягів виробництва.

Серед методів комп'ютерного зору одним із найперспективніших є використання моделей глибинного навчання. Глибокі нейронні мережі можуть досягати високих рівнів достовірності у виявленні об'єктів на зображеннях [2]. Завдяки здатності нейронних мереж вивчати складні патерни та залежності, вони ефективно впораються із виявленням навіть невеликих і складних дефектів, які може бути важко визначити за допомогою традиційних методів.

Аналіз стану проблеми. Друковані плати виготовляються за допомогою спеціальної технології. Спочатку проектується схема, яка включає компоненти, з'єднувальні шляхи та інші елементи. Цей проект потім переноситься на базовий матеріал, яким зазвичай є полімерна плата. Даний процес дозволяє створити фізичну основу для компонентів і дрітків. Після перенесення схеми на базовий матеріал проводиться ряд операцій для створення друкованої плати. Один з етапів – нанесення шарів міді на плату. Шари міді утворюють провідні доріжки, які забезпечують електричне з'єднання між компонентами. Після нанесення міді плату піддають процесу експонування, що дозволяє сформувати контури шляхів і площадок за допомогою фоточутливого матеріалу та масок [3].

Після експонування та видалення зайвих шарів міді плата проходить через травильні розчини, які видаляють непотрібні частинки міді. Цей процес дозволяє сформувати чіткі контури шляхів і площадок, забезпечуючи належну функціональність друкованої плати. Після травлення проводяться інші види обробки, такі як монтаж отворів для компонентів, нанесення захисного шару та покриття плати припоєм. Ці кроки дозволяють забезпечити захист від корозії, підвищити міцність і додати довговічності до друкованої плати.

Під час виробництва, монтажу та використання друкованих плат можуть виникати різні види дефектів, які можуть впливати на їхню функціональність і надійність. Дефекти провідників є одними з найпоширеніших проблем на друкованих платах. Основними видами дефектів провідників є коротке замикання, розрив, «укус миші», шпора, зайва мідь, відсутність отвору [4]. Оскільки дані дефекти є поверхневими, їх можна виявити за допомогою візуально-оптичного контролю. Приклади зображень деяких із перелічених видів дефектів з відкритого набору даних [5] показані на рис. 1.

Візуально-оптичний контроль має важливу перевагу – простоту автоматизації процесу. Завдяки використанню комп'ютерного зору, алгоритмів обробки зображень і машинного навчання, можна розробити програмне забезпечення, яке здатне ав-

томатизовано аналізувати зображення друкованих плат і виявляти наявність дефектів. Це дозволяє значно зменшити залежність від людського фактору, підвищити швидкість і точність контролю, а також знизити витрати на ручну роботу.

Основний принцип методів глибокого навчання полягає в тому, що нейронна мережа навчається на великому наборі зображень друкованих плат, які вже мають позначення щодо наявності або відсутності дефектів та їх положення. Після завершення процесу навчання модель може автоматично аналізувати нові зображення та виконувати детектування дефектів. Глибокі нейронні мережі можуть бути використані для різних завдань виявлення дефектів на друкованих платах, таких як виявлення візуальних аномалій, класифікація дефектів, детектування дефектів і сегментація дефектних областей.

Отже, нейронні мережі є потужним інструментом для виявлення дефектів на друкованих платах. Вони можуть вивчати складні залежності, автоматично визначати діагностичні ознаки, працювати з великими обсягами даних. Це дозволяє в значній мірі автоматизувати процес контролю. Використання нейронних мереж дозволяє досягти високої точності та надійності виявлення дефектів, сприяє прискоренню процесу контролю та зниженню витрат у виробництві.

Автори [6] детально розглядають проблеми контролю якості друкованих плат і пропонують методи автоматизованого оптичного контролю для виявлення дефектів. Робота розпочинається з огляду наявних методів контролю дефектів на друкованих платах та їхніх обмежень. Вона показує, що традиційні методи, такі як візуальний огляд, мають обмежену ефективність і можуть бути витратними та займати багато часу. Тому автори пропонують використовувати автоматизовані системи оптичного контролю на базі нейронних мереж для покращення якості та швидкості процесу контролю дефектів.

Автори [7] стверджують, що через складність умов виробництва друкованих плат більшість попередніх робіт все ще використовують традиційні




Рис. 1. Приклади поверхневих дефектів друкованих плат: а – коротке замикання; б – розрив; в – «укус миші»

алгоритми обробки зображень для автоматизованого виявлення дефектів друкованих плат. Вони запропонували вдосконалений підхід до виявлення дефектів друкованої плати шляхом вивчення глибоких дискримінантних ознак. Це значно зменшило високі вимоги до великого набору даних для методу глибокого навчання. Результати показують кращу продуктивність у класифікації дефектів, ніж інші традиційні методи, засновані на ручному виявленні ознак. За словами авторів, запропонований метод має найвищий показник «mean Average Precision» (mAP) на рівні 99,59 %, що на 8 % перевищує другий за ефективністю метод, який базується на комбінації Alexnet і SVM. Таке значне зростання демонструє високу ефективність глибокого навчання в задачах виявлення поверхневих дефектів друкованих плат. Проте у даній роботі мережа навчалася на штучно створених навчальних зображеннях. Тому при реальному застосуванні показники достовірності контролю можуть відрізнятись.

У [8] стверджується, що традиційні алгоритми, яким заважає неефективність і обмежена точність, не відповідають вимогам сучасних стандартів. На відміну від них, алгоритми виявлення дефектів друкованих плат, засновані на глибокому навчанні, демонструють підвищену достовірність та ефективність. Це додатково підкріплюється їх здатністю навчатись і розпізнавати нові типи дефектів. У дослідженні наведено комплексний аналіз алгоритмів виявлення дефектів друкованих плат на основі машинного зору, який охоплює сфери машинного та глибинного навчання. Автори зазначають, що впровадження безкоштовних наборів даних для виявлення дефектів друкованих плат покращує можливості для оцінки ефективності алгоритмів. Згідно з дослідженнями, в даний час достовірність виявлення та правильної класифікації дефектів може перевищувати 95 % mAP при «Intersection over Union» (IoU) на рівні 0,5. З метою потенційного покращення результатів автори визначили перспективні напрямки майбутніх досліджень для вирішення існуючих проблем у задачах автоматизації виявлення поверхневих дефектів друкованих плат. За результатами досліджень, серед існуючих моделей глибинного навчання найкращу ефективність детектування дефектів друкованих плат демонструє сімейство моделей YOLO.

У [9] для контролю якості друкованих плат пропонується алгоритм глибокого навчання, заснований на використанні моделі «You Look Only Once» (YOLO). У запропонованому методі кваліфіковані інженери з контролю якості спочатку використовують відеоінтерфейс для запису та маркування дефектних друкованих плат. Потім ці

дані використовуються для навчання базової моделі YOLO для виявлення поверхневих дефектів. У цьому дослідженні було використано 11000 навчальних зображень. Запропонована авторами нейронна мережа складається з 24 згорткових і 2 повнозв'язних прошарків. Розглянута модель досягла достовірності виявлення дефектів на рівні 98,79 % за показником mAP. Такий результат підтверджує високу ефективність даних моделей. Проте розглянута авторами архітектура мережі на даний час є застарілою. Тому існує необхідність дослідження сучасніших модифікацій YOLO.

У [10] також стверджується, що традиційний метод ручного виявлення дефектів друкованих плат може не відповідати необхідним виробничим стандартам через високий рівень помилок. У цій роботі автори пропонують вдосконалений алгоритм, заснований на використанні YOLOv4. У дослідженні використовується набір даних про дефекти друкованих плат, опублікований Лабораторією інтелектуальних роботів Пекінського університету, який містить велику кількість зображень різних типів дефектів, що значно підвищує надійність моделі. Автори аналізують розподіл ознак структурного шару CSPDarkNet53 і розподіл розмірів дефектів у наборі даних. На етапі попередньої обробки та введення даних зображення автоматично поділяється відповідно до середнього розміру дефекту на зображенні. Таким способом збільшується ймовірність того, що ділянка містить зображення дефекту. Експериментальні результати показують, що покращений алгоритм на основі YOLOv4 має показник mAP на рівні 96,88 %.

Незважаючи на переваги, дослідники відзначають деякі виклики та обмеження методів глибинного навчання для контролю дефектів друкованих плат. Наприклад, це необхідність наявності великого обсягу попередньо оброблених зображень дефектів для навчання моделей, а також важкість управління різноманітністю та репрезентативністю дефектів.

У цілому, автоматизований візуально-оптичний контроль з використанням моделей глибинного навчання є потужним інструментом для виявлення поверхневих дефектів на друкованих платах. Враховуючи швидкий прогрес у сфері машинного навчання, можна очікувати подальшого розвитку цього підходу для контролю дефектів друкованих плат. Одним із перспективних напрямів досліджень є використання моделей сімейства YOLO. Саме ці моделі демонструють найкращі результати на різних наборах навчальних даних. Особливий інтерес становить модифікація YOLOv5, ефективність якої в задачах автоматизованого детектуван-

ня дефектів друкованих плат на даний момент не була достатньо висвітлена в наукових публікаціях.

Постановка задачі. Метою даного дослідження є аналіз ефективності застосування нейронної мережі YOLOv5 при автоматизованому виявленні поверхневих дефектів на зображеннях друкованих плат. Такий підхід дозволить в автоматизованому режимі виявляти місце розташування дефектів і проводити класифікацію за типом. У реальній системі зображення об’єкту контролю надходять до блоку інтелектуального цифрового опрацювання зі спеціальної камери, встановленої на виробничій лінії або безпосередньо над виробом. Зображення в автоматичному режимі опрацьовуються нейронною мережею. На виході нейромережевого модуля отримується зображення, на якому дефекти виділяються в рамку та класифікуються за типом.

Опис нейромережевої моделі. YOLO – це архітектура нейронних мереж для детектування об’єктів і класифікації, яка має значний прогрес у швидкості та точності порівняно зі своїми попередниками. Одна з головних переваг даної моделі полягає в тому, що вона має високу швидкість обробки зображень. Це дозволяє використовувати її для роботи в реальному часі на мобільних пристроях. Крім того, YOLO показує високу точність виявлення об’єктів на різних наборах даних. Базова версія архітектури YOLO описана в [11].

Проте у початкової версії YOLO також є деякі недоліки. Наприклад, архітектура може мати проблему з виявленням малих об’єктів або об’єктів, форма яких може змінюватись. Також можуть виникати проблеми з локалізацією об’єктів, особливо коли вони перекриваються або мають схожі ознаки. Тому дана модель має велику кількість модифікацій, які покращують її ефективність.

YOLOv5 (You Only Look Once version 5) є оновленою версією алгоритму YOLO, яка була представлена в 2020 р. [12]. YOLOv5 має декілька розмірів моделей, таких як YOLOv5s, YOLOv5m, YOLOv5l та YOLOv5x, які відрізняються за кількістю шарів та обчислювальною потужністю. Наприклад, модель YOLOv5x має близько 88 мільйонів параметрів. Узагальнену архітектуру YOLOv5 описано в [13] та показано на рис. 2.

YOLOv5 також відрізняється високою точністю виявлення об’єктів. Наприклад, модель YOLOv5x досягає близько 47 % mAP на датасеті MS COCO при використанні роздільної здатності 640×640 і тренуванні протягом 300 епох. Кількість внутрішніх параметрів залежить від розміру моделі, від XS (14 мільйонів параметрів) до XL (177 мільйонів параметрів). Швидкодія теж може варіюватися залежно від розміру моделі.

У моделі YOLOv5 використовується функція активації Mish, що є нелінійною функцією, яка використовується для введення нелінійності в нейронній мережі. Вона визначається наступним чином:

$$\text{Mish}(x) = x \cdot \tanh(\text{softplus}(x)) \tag{1}$$

Функція активації Mish має плавний градієнт, що допомагає уникнути проблеми з затуханням градієнта, яка може виникати в інших функціях активації, таких як Sigmoid або ReLU. Вона також дозволяє зберегти більше інформації у вихідному сигналі, що може покращити точність моделі.

У порівнянні з YOLOv1 та YOLOv3, YOLOv5 має кращу швидкість і точність. Вона також забезпечує простішу та легшу використання архітектуру, що робить її зручним варіантом для розробників і дослідників. Порівняння кількісних характеристик різних модифікацій YOLO наведе-




Рис. 2. Архітектура YOLOv5

Таблиця 1. Порівняння модифікацій YOLO

Параметр	YOLOv1	YOLOv3	YOLOv5
Швидкодія	45...60 FPS	20...30 FPS	20...40 FPS
Внутрішні параметри	45,0M	61,0M	85,0M
mAP	63 %	57 %	70 %

дено в табл. 1. Всі вказані моделі були навчені та протестовані на наборі даних MS COCO [14].

Узагальнюючи вищенаведене, YOLOv5 виступає як кращий вибір порівняно з попередніми модифікаціями. Вона забезпечує баланс між точністю та продуктивністю, що робить її популярним рішенням для різноманітних завдань виявлення об’єктів.

Метрики для виявлення об’єктів. Наступні метрики використовуються для порівняння та оцінки ефективності алгоритмів детектування об’єктів. Вони допомагають визначити, наскільки точно та повно виявляються об’єкти, а також як алгоритм справляється з різними розмірами та орієнтацією об’єктів. Використання цих метрик дозволяє оцінити якість алгоритму та порівняти його з аналогічними рішеннями. Найпопулярнішими є метрики IoU, Precision, Recall, mAP50 та mAP50-95 [15]. Значення усіх вказаних метрик може знаходитись в діапазоні 0...1, причому 1 означає ідеальний результат.

IoU (Intersection over Union) є метрикою, що використовується для оцінки перекриття двох областей. У контексті детектування об’єктів, IoU вимірює ступінь перекриття між прогнозованою областю (виявлений об’єкт) та опорною областю (ідеальною або анотованою областю об’єкту).

$$IoU = \frac{\text{Площа перекриття}}{\text{Площа об'єднання}} \tag{2}$$

Precision (P) вимірює, яка частка об’єктів, виявлених алгоритмом, є дійсно коректними. Вона обчислюється як відношення кількості правильно виявлених об’єктів до загальної кількості об’єктів, виявлених алгоритмом. Висока P означає малу кількість неправильно виявлених об’єктів.

$$P = \frac{TP}{TP + FP}, \tag{3}$$

де TP – кількість правильно виявлених об’єктів; FP – кількість неправильно виявлених об’єктів.

Recall (R) вимірює, яка частка дійсно присутніх об’єктів була виявлена алгоритмом. Вона обчислюється як відношення кількості правильно виявлених об’єктів до загальної кількості дійсно присутніх об’єктів. Висока R означає, що алгоритм виявляє більшу частину об’єктів.

$$R = \frac{TP}{TP + FN}, \tag{4}$$

де TP – кількість правильно виявлених об’єктів; FN – кількість пропущених об’єктів.

mAP за порогу в 50 % IoU (mAP50) вимірює якість класифікації виявлених об’єктів. mAP50 означає, що об’єкт вважається правильно виявленим, якщо його перекриття з прогнозованою рамкою (IoU) складає не менше 50 %. Вища mAP50 вказує на кращу точність класифікації об’єктів.

$$mAP50 = \frac{(AP50_1 + AP50_2 + \dots + AP50_N)}{N}, \tag{5}$$

де AP – середня Precision по класам.

mAP в діапазоні 50...95 % IoU (mAP50-95) вимірює якість виявлення об’єктів в діапазоні IoU 50...95 %. Вона оцінює здатність алгоритму до стійкого виявлення об’єктів за різних рівнів перекриття. Вища mAP50-95 вказує на кращу стійкість алгоритму до зміни розмірів та орієнтації об’єктів.

$$mAP50-95 = \frac{(AP50-95_1 + AP50-95_2 + \dots + AP50-95_N)}{N}, \tag{6}$$

Опис параметрів навчання моделі. Для навчання нейронної мережі використано відкритий набір даних «PCB defects». Початковий набір даних складається з 1386 зображень, які відображають 6 типів дефектів на друкованих платах: відсутній отвір, «укус миші», розрив ланцюга, замикання, шпора та паразитна мідь. Кожен тип дефекту рівномірно представлений в наборі даних, що дозволяє виконувати різноманітні завдання, пов’язані з детектуванням дефектів. Набір даних детально описаний в [5].

Проте початкові зображення з зазначеного набору мають занадто високу роздільну здатність. Тому було вирішено розділити кожне зображення на частини розміром 600×600 пікселів. Кінцевий набір для навчання містить 9920 зображень, тоді як набір для тестування містить 2508 зображень.

Для реалізації нейромережі використовується фреймворк PyTorch, який є одним з найпопулярніших і найпотужніших інструментів для розробки та навчання нейромереж. PyTorch забезпечує гнучкість і простоту в роботі з тензорами, що дозволяє легко будувати, тренувати та валідувати нейромережеву модель.

Тренування моделі YOLOv5s було здійснене з використанням наступних параметрів: розмір вхідного зображення – 416×416, розмір батчу – 16, кількість епох – 300, ваги попередньо навченої моделі – YOLOv5s на наборі MS COCO. Інші гіперпараметри залишено за замовчуванням для базової мережі YOLOv5.

Графіки навчання наведено на рис. 3. Можна зробити висновок, що навчання завершено успішно, ознак перенавчання немає.

Аналіз результатів. Приклади результатів роботи навченої мережі для детектування дефектів на зображеннях із тестового набору показано на рис. 4.




Рис. 3. Графіки процесу навчання

Можна помітити, що мережа здатна успішно виявляти дефекти різних класів і розмірів. У тому числі, успішно розпізнають навіть невеликі за площею дефекти. Оскільки зображення друкованих плат містять багато різноманітних структурних елементів, пошук дефектів вручну зайняв би значний час та потребував би великої уваги та досвіду оператора. Натомість, швидкість опрацювання одного зображення нейронною мережею склала 14,7 мс.

Оцінка роботи нейронної мережі включає також кількісні метрики. Результати кількісної оцінки ефективності моделі на тестовій множині наведено в табл. 2.

Модель YOLOv5s продемонструвала високу ефективність у виявленні об’єктів на зображеннях. Загальна P становить 0,941, що означає, що більшість виявлених об’єктів є правильними. Однак, R має значення 0,894, що свідчить про те, що

деякі об’єкти можуть бути пропущені або недостатньо виявлені.

Серед конкретних класів дефектів пропущений отвір демонструє високі P = 1,000 та R = 0,997, що вказує на ефективну здатність моделі виявляти цей тип дефекту. Схожі показники спостерігаються для класу «коротке замикання» з P = 0,989 і R = 0,969. Ці результати підтверджують ефективність моделі в розпізнаванні цих конкретних класів дефектів.

У той же час, деякі класи, такі як розрив, шпора та надлишкова мідь, показують нижчі значення P та R. Наприклад, розрив має значення P = 0,838 і R = 0,800. Це може вказувати на те, що модель може потребувати додаткового навчання або оптимізації для виявлення цих типів дефектів.

Крім того, метрики mAP50 та mAP50-95 також вказують на загальну достовірність класифі-




Рис. 4. Приклади детектування різних класів дефектів

Таблиця 2. Результати тестування моделі

Клас дефекту	Кількість зразків	P	R	mAP50	mAP50-95
Всі	596	0,941	0,894	0,925	0,459
Пропуск отвору	105	1,000	0,997	0,995	0,561
«Укус миші»	104	0,894	0,888	0,918	0,450
Розрив	100	0,838	0,800	0,884	0,411
Коротке замикання	90	0,989	0,969	0,981	0,487
Шпора	98	0,953	0,829	0,861	0,424
Надлишкова мідь	99	0,970	0,879	0,910	0,424

кації дефектів. Значення mAP50 становить 0,925, що свідчить про хорошу здатність моделі класифікувати об'єкти при IoU = 50 %. Однак, значення mAP50-95 дорівнює 0,459. Це означає, що в моделі зі збільшенням IoU доля правильних класифікацій знижується.

Враховуючи якісну оцінку, яка показує гарну якість виявлення об'єктів на зображеннях, і кількісну оцінку, що вказує на швидкодію та ефективне використання ресурсів, можна зробити висновок про високу ефективність роботи нейронної мережі YOLOv5s у детектуванні поверхневих дефектів на зображеннях друкованих плат.

На основі наведених даних також можна запропонувати кілька шляхів для подальшого розвитку автоматизованих систем детектування поверхневих дефектів друкованих плат. Першим напрямом є використання потужніших моделей. Варто розглянути можливості використання сучасніших архітектур нейронних мереж, які мають високу точність виявлення об'єктів на стандартних наборах даних, таких як MS COCO. Потенційно ці моделі можуть забезпечити кращу якість детектування та здатність розпізнавання ширшого спектру об'єктів.

Ще одним напрямом для подальших досліджень є аугментація даних. Використання різноманітних методів аугментації дозволить розширити навчальний набір даних і покращити здатність моделі до узагальнення та розпізнавання дефектів у різних умовах зйомки.

Наостанок, важливим завданням є оптимізація гіперпараметрів обраної моделі глибинного навчання. Варто провести додаткові експерименти з дослідження впливу batch size, активаційних функцій, бекбонів та інших параметрів на ефективність детектування дефектів. Це допоможе знайти оптимальні за показником достовірності контролю значення, які забезпечать кращу якість виявлення дефектів і швидкодію моделі.

Вибір конкретних шляхів удосконалення методу автоматизованого детектування поверхневих дефектів друкованих плат повинен залежати від контексту, ресурсів і цілей розробки. На результат впливатимуть умови зйомки, характеристики об'єкту контролю, особливості архітектури моделі глибинного навчання тощо.

Висновки

У роботі проведено детальний аналіз ефективності автоматизованого детектування поверхневих дефектів друкованих плат із використанням нейронної мережі YOLOv5. Існуючі дослідження підтверджують актуальність використання методів штучного інтелекту для автоматизації опрацювання даних візуально-оптичного контролю друкованих плат. Порівняно з попередніми версіями, мо-

дифікація YOLOv5 має підвищену швидкодію та достовірність результатів роботи.

Розглянутий метод автоматизованого виявлення поверхневих дефектів друкованих плат на основі нейронної мережі YOLOv5 показав високу ефективність. Мережа здатна виявляти навіть дрібні дефекти та класифікувати їх з достовірністю mAP50 = 92,5 %. Результати дослідження вказують на потенціал системи для використання в промислових умовах. Потрібно також врахувати, що модель навчалась на зображеннях, які були отримані камерою з роздільною здатністю 8 МП. Мінімальний розмір дефектів, які модель здатна виявити, залежить від великої кількості факторів, таких як умови зйомки, чіткість зображення, масштаб моделі, обрані гіперпараметри моделі тощо.

Розглянута модель YOLOv5s найкраще розпізнає такі критичні дефекти, як пропуск отвору та коротке замикання. Проте важливий дефект типу «розрив» виявляється з нижчою достовірністю. Це можна пояснити візуальною подібністю дефектних розривів і необхідних розривів доріжок, які передбачені дизайном плати. З тих самих причин можуть недостовірно розпізнаватись дефекти типу «надлишкова мідь». З найнижчою достовірністю розрізняється дефект «шпора», однак даний вид дефектів за нормальних експлуатаційних умов не має значного впливу на надійність роботи плати. В цілому, розглянута система лише допомагає автоматизовано виявити дефекти. Кінцеве діагностичне рішення щодо їх критичності та впливу на стабільність роботи плати має прийматись кваліфікованим фахівцем.

Автоматизація візуально-оптичного контролю друкованих плат залишається актуальним напрямом досліджень. Подальший розвиток нових алгоритмів обробки зображень, використання штучного інтелекту та вдосконалення апаратного забезпечення можуть помітно покращити швидкість, точність і надійність процесу контролю. На даний момент також відомі новітні модифікації YOLOv7 та YOLOX, які потребують додаткового вивчення у майбутньому.

Список літератури/References

1. Стещенко Я.В., Момот А.С., Протасов А.Г., Муравйов О.В. (2023) Автоматизація процесу сегментації зображень дефектів металевих поверхонь з використанням нейронної мережі U-Net. *Техн. діагност. та неруйнівн. контроль*, 2, 34–40. DOI: <https://doi.org/10.37434/tdnk2023.02.05>
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. *Tekhn. Diagnost. ta Neruiniv. Kontrol*, 2, 34–40. DOI: <https://doi.org/10.37434/tdnk2023.02.05>
2. Ling, Q., Isa, N.A. (2023) Printed circuit board defect detection methods based on image processing, machine learning and deep learning: A survey. *IEEE Access*, 11, 15921–15944. DOI: <https://doi.org/10.1109/access.2023.3245093>

3. Khandpur, R.S. (2006) *Printed circuit boards: Design, fabrication, assembly and testing*. New York, McGraw-Hill.

4. Zhou, Y., Yuan M., Zhang J. et al. (2023) Review of vision-based defect detection research and its perspectives for printed circuit board. *J. of Manufacturing Systems*, **70**, 557–578. DOI: <https://doi.org/10.1016/j.jmsy.2023.08.019>

5. Akhatova, A. (2021) *PCB defects*, Kaggle. Available at: <https://www.kaggle.com/datasets/akhatova/pcb-defects> (Accessed: 03 March 2024) [in English].

6. Cao, X. (2023) A real-time automated visual inspection system for printed circuit boards missing footprints detection. *Int. J. of Advanced Computer Science and Applications*, **14**(5). DOI: <https://doi.org/10.14569/ijacsa.2023.0140537>

7. Zhang, C., Shi W., Li X. et al. (2018) Improved bare PCB defect detection approach based on Deep Feature Learning. *The J. of Engineering*, **16**, 1415–1420. DOI: <https://doi.org/10.1049/joe.2018.8275>

8. Chen, X., Wu Y., He X., Ming W. (2023) A comprehensive review of deep learning-based PCB defect detection. *IEEE Access*, **11**, 139017–139038. DOI: <https://doi.org/10.1109/access.2023.3339561>

9. Adibhatla, V.A., Chih H., Hsu C. et al. (2020) Defect detection in printed circuit boards using you-only-look-once convolutional neural networks. *Electronics*, **9**(9), 1547. DOI: <https://doi.org/10.3390/electronics9091547>

10. Xin, H., Chen, Z., Wang, B. (2021) PCB electronic component defect detection method based on improved YOLOv4 algorithm. *J. of Physics: Conference Series*, **1827**(1), 012167. DOI: <https://doi.org/10.1088/1742-6596/1827/1/012167>

11. Redmon, J., Divvala S., Girshick R., Farhadi A. (2015) *You Only Look Once: Unified, Real-Time Object Detection*. Computer Vision and Pattern Recognition [Preprint]. DOI: <https://doi.org/10.48550/arXiv.1506.02640>

12. 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. DOI: <https://doi.org/10.1016/j.dsp.2022.103514>

13. Xu, R., Lin, H., Lu, K. et al. (2021) ‘A forest fire detection system based on Ensemble Learning’. *Forests*, **12**(2), 217. DOI: <https://doi.org/10.3390/f12020217>

14. Jiang, P., Ergu, D., Liu, F. et al. (2022) A review of YOLO algorithm developments. *Procedia Computer Science*, **199**, 1066–1073. DOI: <https://doi.org/10.1016/j.procs.2022.01.135>

15. Skladchykov, I., Momot, A., Galagan, R. et al. (2022) Application of YOLOX deep learning model for automated object detection on thermograms. *Information extraction and processing*, **50**, 69–77. DOI: <https://doi.org/10.15407/vidbir2022.50.069>

AUTOMATED DEFECT DETECTION IN PRINTED CIRCUIT BOARDS BASED ON THE YOLOV5 NEURAL NETWORK

A.S. Momot, V.V. Kretsul, O.V. Muraviov, R.M. Galagan

National Technical University of Ukraine «Igor Sikorsky Kyiv Polytechnic Institute». 37 Beresteysky Ave., 03056, Kyiv, Ukraine.
E-mail: drewmomot@gmail.com; asnk@kpi.ua

In the paper, we consider the possibilities of applying the YOLOv5s deep learning model to the task of automating the process of detecting surface defects on printed circuit boards. Modern printed circuit boards are manufactured in large volumes and contain a significant number of elements. The manufacturing process of printed circuit boards is complex, which increases the likelihood of board wiring defects, such as short, open circuits, mouse bites, etc. These defects are superficial and can be detected by visual and optical inspection. Compared to other methods, the visual-optical inspection is easier to automate. It is proven that it is promising to use deep learning models to automate the process of detecting objects in images. Modern neural networks can automatically detect surface defects in printed circuit board images with high reliability. The paper considers the YOLO class of models. It is established that the YOLOv5 model has better performance and recognition accuracy than previous modifications. In this study, the YOLOv5s model was implemented and trained to test the effectiveness of this network in the task of automated detection of surface defects on printed circuit boards. The open «PCB Defects» dataset was used for training. A qualitative and quantitative analysis of the performance of the trained network on a test dataset was carried out. It was found that the network can detect surface defects of printed circuit boards with 92.5 % reliability in terms of mAP50. Additionally, the results of the recognition of different classes of defects are analyzed and recommendations for further improvement of the system are given. In particular, it is promising to apply augmentation of training data and use a more complex architecture of the deep learning model. 15 Ref., 2 Tabl., 4 Fig.

Keywords: PCB defects, object detection, deep learning, YOLOv5

Отримано 04.03.2024
Отримано у переглянutoму вигляді 26.03.2024
Прийнято 11.06.2024

Вперше в історії людства супутник передав на Землю сонячну енергію з космосу

Команда дослідників використовувала пристрій, який представляє невеликий супутник, здатний збирати сонячну енергію за допомогою фотоелектричних елементів і перетворювати її в радіочастотну енергію за допомогою антенних решіток.

Потім супутник синтезував промінь радіочастотної енергії і передав його на Землю, де приймач і перетворювач, розташований на даху лабораторії в Каліфорнійському технологічному інституті, вловив і перетворив сигнал на постійний струм.

Кінцева мета розробників – створення мережі супутників, які зможуть передавати на Землю енергію, достатню для забезпечення 10000 домогосподарств. Однак до цього ще далеко, оскільки поточний експеримент зафіксував лише частину енергії, що генерується супутником.

Космічна сонячна енергетика – це багатообіцяюча концепція, яка має на меті використати неосяжну і безперерйну сонячну енергію, доступну в космосі, і доставити її на Землю, де вона може бути використана для промисловості, домогосподарств та інших цілей.

На відміну від наземних сонячних панелей, на роботу яких впливають погода, пори року та нічний час доби, орбітальні сонячні панелі можуть генерувати енергію безперервно, якщо вони орієнтовані на сонце.

