



О. В. Федак, Р. А. Мельник

Національний університет "Львівська Політехніка", м. Львів, Україна

СИСТЕМА ВИЯВЛЕННЯ ДЕФЕКТІВ НА ДРУКОВАНИХ ПЛАТАХ З ВИКОРИСТАННЯМ МОДЕЛІ ПІДСИЛЕННЯ УВАГИ ДО ПОШКОДЖЕНЬ

Виконано детальний аналіз актуальних методів автоматичного виявлення дефектів на друкованих платах РСВ (англ. *Printed Circuit Board*). Виявлено недоліки у традиційних методах оброблення зображень, які обмежують ефективність їхнього застосування за складних виробничих умов, таких як обмежена освітленість або дрібні дефекти, які важко ідентифікувати класичними підходами до виявлення пошкоджень на РСВ. Запропоновано методику виявлення дефектів, яка використовує модель підсилення уваги до пошкоджень DAAM (англ. *Defect Attention Augmentation Model*) у поєднанні з глибинними згортковими нейронними мережами CNN (англ. *Convolutional Neural Network*) для підвищення точності їх локалізації на підставі аналізу масок і різницевого зображення, які утворені внаслідок обчислення різниці між двома зображеннями для виявлення змін або дефектів, що дає змогу виділити навіть дрібні пошкодження. Використано U-Net-архітектуру моделі, оскільки вона забезпечує краще виділення важливих фрагментів зображення порівняно з класичними моделями. Виконано реалізацію системи виявлення пошкоджень на друкованих платах за допомогою фреймворку PyTorch, який дає змогу розробити та навчити нейронну мережу. Реалізовано функцію створення різницевого зображення для підвищення точності виявлення дефектів на друкованих платах. Функція створення різницевого зображення дає змогу виділити зміни та аномалії на поверхні РСВ. Здійснено попереднє оброблення обох зображень за допомогою Гаусового згладжування, що дає змогу зменшити шум на зображеннях. Застосовано як початкові дані маски дефектів різних класів (missing hole, mouse bite, open circuit, short, spur). Виконано попередню розмітку зображень та їх розподіл за класами, сформовано карту розміток для навчання моделі. Проведено навчання моделі у 10 епохах із використанням функції втрат CrossEntropyLoss. Отримано результати, які показали досягнення точності 97 % на тестових даних для більшості класів дефектів, водночас відзначено незначне зниження точності (до 93 %) у випадках, коли дефекти мають складну форму або мінімальні розміри (≤ 1000 мкм). Все це потребує подальшого вдосконалення моделі виявлення пошкоджень на друкованих платах або збільшення обсягу даних для її навчання. Систему виявлення пошкоджень на РСВ можна застосовувати під час виготовлення друкованих плат для контролю їх якості та в інших галузях, дотичних до електроніки. Це дасть змогу підвищити ефективність виготовлення друкованих плат, зменшити кількість їхнього браку та оптимізувати виробничі процеси. Також система може бути корисною в науково-дослідних цілях для створення нових технологій контролю якості виготовлення продукції.

Ключові слова: виявлення дефектів; друковані плати; глибинні згорткові нейронні мережі; сегментація зображень; механізм підсилення уваги до пошкоджень.

Вступ / Introduction

Галузь автоматичного виявлення дефектів на зображеннях друкованих плат зазнала значного прогресу, адже це ключовий етап у забезпеченні якості електронної продукції. Проте, залишається низка проблем, які ускладнюють досягнення високої точності та швидкодії процедури виявлення дефектів: велика кількість їх різновидів, варіативність форми та розміру, наявність візуальних артефактів, а також вплив умов освітлення та шумів на зображенні.

Ці фактори ускладнюють використання простих методів оброблення зображень і вимагають застосування глибинних нейронних мереж, здатних адаптуватися до складних даних. Однак, навіть сучасні моделі виявлення дефектів стикаються з проблемою правильного виді-

лення їхніх істотних ознак, що впливає на точність виконання цієї процедури. Тому виникає потреба удосконалення архітектур нейронних мереж шляхом інтеграції механізмів підсилення уваги до дефектів, які дають змогу зосереджувати увагу на важливих ділянках зображення.

Об'єкт дослідження – виявлення дефектів на зображеннях друкованих плат.

Предмет дослідження – методи та засоби виявлення пошкоджень на друкованих платах, що базуються на аналізі різницевого зображення та модулі DAAM, що дасть змогу підвищити точність сегментації пошкоджень за рахунок фокусування уваги на найзначніших змінах між еталонним і тестовим зображеннями.

Мета роботи – розробити систему виявлення пошкоджень на друкованих платах з використанням моделі

Інформація про авторів:

Федак Олег Васильович, магістрант, кафедра програмного забезпечення.

Email: oleh.fedak.mpzip.2024@lpnu.ua; <https://orcid.org/0009-0006-8643-0571>

Мельник Роман Андрійович, д-р техн. наук, професор, кафедра програмного забезпечення.

Email: ramelnik@polynet.lviv.ua; <https://orcid.org/0000-0002-4329-6740>

Цитування за ДСТУ: Федак О. В., Мельник Р. А. Система виявлення дефектів на друкованих платах з використанням моделі підсилення уваги до пошкоджень. Науковий вісник НЛТУ України. 2025, т. 35, № 5. С. 160–166.

Citation APA: Fedak, O. V., & Melnyk, R. A. (2025). System for detecting defects on printed circuit boards using attention mechanism enhancement model. *Scientific Bulletin of UNFU*, 35(5), 160–166. <https://doi.org/10.36930/40350518>

підсилення уваги до них, яка дасть змогу ефективно ідентифікувати дефекти на підставі комбінації масок.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

- здійснити аналіз актуальних методів і підходів до виявлення дефектів на друкованих платах для визначення їхньої ефективності застосування, що дасть змогу зіставити переваги та недоліки класичних і глибоких підходів до виявлення пошкоджень на РСВ;
- визначити особливості реалізації системи виявлення пошкоджень на друкованих платах на підставі аналізу різницевого зображення та модуля DAAM для підвищення точності сегментації дефектів, що дасть можливість зменшити кількість хибних спрацювань, підвищити чутливість моделі до локальних аномалій та уникнути хибних спрацювань;
- дослідити вплив попереднього оброблення зображень та параметрів моделі на якість та стабільність результатів за умов змінного освітлення, що забезпечить надійність та стабільність результатів виявлення пошкоджень на друкованих платах за змінних параметрів середовища, зменшить ризик хибних спрацювань;
- виконати порівняльний аналіз ефективності запропонованого рішення із наявними методами виявлення дефектів на друкованих платах, результати якого уможливають об'єктивну оцінку переваг і недоліків запропонованого підходу, визначення його точності та надійності порівняно з наявними методами.

Аналіз останніх досліджень та публікацій. Сучасні системи виявлення пошкоджень на РСВ дедалі ширше застосовують алгоритми машинного та глибокого навчання нейронної мережі для задач пошуку та класифікації пошкоджень на РСВ. Аналіз наукових праць з цієї тематики показує велику кількість різних підходів, від класичних CNN до інноваційних рішень із використанням моделей виявлення пошкоджень на РСВ з підкріпленням і генеративних моделей.

У роботі [4] наведено аналіз методів глибокого навчання нейронних мереж, що застосовуються для виявлення дефектів на друкованих платах. Автор зосереджує увагу на згорткових нейронних мережах, їхніх різновидах архітектур та оптимізаційних підходах. Проаналізувавши наукові джерела, з'ясовано, що класичні CNN-моделі виявляють помітні дефекти із високою точністю в межах 85-92 %. Однак, для дрібних дефектів традиційні CNN не завжди забезпечують необхідну чутливість. Це обґрунтовує актуальність подальших досліджень у напрямі високочутливих алгоритмів.

У роботі [8] розроблено алгоритм виявлення дефектів на друкованих платах із застосуванням методів глибокого навчання нейронної мережі. Автори запропонували модульну архітектуру виявлення пошкоджень на РСВ, яка складається з двох окремих детекторів: перший – для класифікації дефектів за категоріями, другий – для локалізації аномалій на платі. Ця комбінована стратегія дала змогу значно підвищити точність моделі, яка у тестових наборах даних досягала 92-95 %. Також було застосовано техніки регуляризації та адаптивного навчання нейронної мережі, що зменшило вплив шуму на зображеннях та підвищило стабільність результатів за складних умов. Висновки статті підтверджують, що запропонований підхід є перспективним для автоматизації контролю якості друкованих плат. Незважаючи на високі показники точності, автори відзначають нагальну потребу подальшого розвитку алгоритмів, здатних ефективно працювати з малопомітними дефектами.

У роботі [3] пропонують метод виявлення дефектів на друкованих платах із використанням автоенкодера зі з'єднаннями пропускового типу (skip connections). Модель поєднує властивості енкодера-декодера з пропусковими зв'язками для збереження просторової інформації, що дозволило точно ідентифікувати дрібні дефекти, включно з тріщинами та відсутніми компонентами. Тестування на великих наборах даних показало точність понад 90 % за збереження високої чутливості до малопомітних аномалій.

У роботі [13] наведено метод виявлення дефектів на збірках друкованих плат за допомогою YOLOv5. Автори інтегрували просторовий пірамідний пулінг і великокрокові згортки для покращення локалізації дефектів та підвищення точності моделі. Система сягає точності понад 93 % для різних типів дефектів.

У роботі [16] автори представляють метод виявлення дефектів на друкованих платах із застосуванням удосконаленого алгоритму YOLO – CDI-YOLO. Основна мета дослідження полягає у підвищенні точності та швидкості виявлення дефектів. Автори інтегрували адаптивний механізм масштабування та модуль фокусування уваги на деталях для точного виявлення дрібних дефектів, таких як тріщини, подряпини та неповні пайки. Тестування на великих наборах даних продемонструвало точність понад 94 %. Незважаючи на високі показники, автори відзначають, що алгоритм потребує додаткового тестування на різних типах плат. Робота підтверджує перспективність алгоритмів глибокого навчання нейронної мережі та механізмів уваги для забезпечення надійної та швидкої перевірки якості плат.

У роботі [10] автори запропонували легку модель SCF-YOLO для виявлення дефектів на друкованих платах із акцентом на швидкодію та ефективність обчислень. Автори наголошують, що класичні YOLO-моделі добре виявляють великі пошкодження, але часто пропускають дрібні дефекти. SCF-YOLO використовують модуль селективного об'єднання ознак та оптимізований фільтр для підвищення розпізнавання дрібних об'єктів, досягаючи точності 91-93 %.

У роботі [5] запропоновано підхід до виявлення дефектів на поверхні друкованих плат з використанням вдосконаленої моделі Faster R-CNN із інтеграцією Feature Pyramid Network (FPN). Удосконалена модель FPN дає змогу захоплювати багаторівневі ознаки, що підвищує точність понад 92 %, при цьому ефективно виявляються дрібні та середні дефекти на складному фоні та за різних умов освітлення. Автори зазначають, що система може працювати стабільно, але потребує оптимізації через високі ресурсні витрати.

Проаналізувавши наукову літературу, з'ясовано, що у наявних дослідженнях немає робіт, які поєднують підхід на підставі аналізу різницевого зображення з модулем уваги DAAM для підвищення точності сегментації. Це створює наукову та практичну потребу у проведенні цього дослідження, оскільки запропонований підхід може значно підвищити чутливість моделі до локальних змін, зменшити кількість хибних спрацювань.

Матеріали та методи дослідження. Для моделі для виявлення пошкоджень на РСВ було обрано набір даних, який містить зображення без дефектів та з дефектами [2]. Цей набір даних містить 115 зображень для кожного класу: відсутність отворів (missing hole), пошкодження доріжок (mouse bite), розімкнений ланцюг

(open circuit), коротке замикання (short), шпори (spur). Для попереднього оброблення дефектного та еталонного зображення було обрано метод Гаусового згладжування [12].

Результати дослідження та їх обговорення / Research results and their discussion

Запропонована система виявлення пошкоджень на друкованих платах. Для реалізації системи автоматичного виявлення дефектів на друкованих платах обрано мову програмування Python як основу завдяки її широкій екосистемі бібліотек для комп'ютерного зору та глибокого навчання нейронних мереж. Розроблення здійснювалося у середовищі Visual Studio Code.

Як фреймворк для навчання нейронних мереж застосовано PyTorch, який забезпечує високу продуктивність, динамічне обчислення графів та простоту реалізації кастомних модулів. Для оброблення зображень використовують бібліотеки OpenCV та NumPy.

Апаратні вимоги [13]:

- процесори: Intel Core i5 або аналогічний;
- оперативна пам'ять: 4 GB і більше;
- вільне місце на диску: від 500 MB для програми та розроблених моделей;
- відеокарта: рекомендовано NVIDIA GPU з підтримкою CUDA.

Програмні вимоги: операційна система Windows 8 і вище, Ubuntu 20.04 і вище.

Алгоритм виявлення пошкоджень на друкованих платах. Модель DAAM (англ. *Defect Attention Augmentation Model*) є складною нейронною мережею для сегментації зображень із застосуванням механізму уваги на підставі різниці між ознаками двох зображень. Вхідними даними є тензор, який представляє різницеве зображення, що дає змогу виділяти зміни та аномалії, наприклад дефекти на друкованих платах. Основна ідея полягає у поєднанні принципів класичної U-Net-архітектури нейронних мереж з модулем уваги, який спеціально розроблений для роботи з різницевиими ознаками, тобто піксельними значеннями, отриманими внаслідок порівняння двох зображень, які тільки відображають їхні відмінності. Модель складається з енкодера, модуля DAAM, декодера та фінального шару, який генерує маску дефектів.

Енкодер є послідовністю конволюційних блоків, кожен з яких відповідає за виділення ознак різної складності. Перший блок енкодера приймає на вхід зображення із трьома каналами і перетворює його на 64 канали ознак, в такий спосіб формує початковий рівень наведення. Другий блок приймає ці 64 канали ознак та перетворює їх на 128 каналів, зменшуючи просторовий розмір наполовину, що дає змогу захоплювати більш абстрактні ознаки. Третій блок працює 128 каналами та перетворює на 256 каналів. Отже, отримується глибоке наведення зображення, яке містить інформацію про глобальні структури та потенційні дефекти за допомогою операції MaxPooling [18].

Після того, як ознаки були витягнуті енкодером, вони передаються в модуль DAAM. Цей модуль є ключовим компонентом моделі, адже він відповідає за виділення різниці між ознаками референсного та поточного зображень, у такий спосіб фокусує модель на тих ділянках, де присутні відмінності. На вході DAAM приймає два тензори ознак: один для референсного зображення,

другий – для поточного. Модуль обчислює різницю між цими двома тензорами. Результатом різниці є утворення карти змін. Надалі ця різниця обробляється у такий спосіб: зменшується кількість каналів до 128 і після цього застосовується ReLU, щоб забезпечити нелінійне наведення ознак різниці. Далі різницевиий тензор зменшується до одного каналу для формування карти уваги. Для перетворення значень від 0 до 1 застосовується функція sigmoid. Результатом роботи функції виходить маска уваги, яка підкреслює ті області, де різниця найбільш значуща. Далі маска уваги множить на ознаки поточного зображення, що дає змогу підсилити важливі пікселі, відповідальні за дефекти, приглушить неважливі для забезпечення кращої сегментації.

Після оброблення ознак модулем DAAM вони передаються в декодер, який відповідає за відновлення просторових розмірів зображення і формування остаточної маски за допомогою операції Upsample. Особливістю декодера є наявність skip connections, які дають змогу об'єднувати ознаки з відповідних рівнів енкодера з поточними ознаками декодера через конкатенацію по каналному виміру. Це забезпечує збереження локальних деталей, які можуть бути втрачені під час зменшення просторових розмірів в енкодері. Перший блок декодера обробляє вихід DAAM й об'єднує його з ознаками другого рівня енкодера, другий блок об'єднує отримані ознаки з першим рівнем енкодера, а третій блок декодера формує остаточний тензор ознак для генерації маски.

Фінальний шар моделі перетворюється з багатоканального тензора на одноканальний, що відповідає масці дефектів, даючи можливість моделі генерувати точне бінарне відображення дефектів на зображенні. Після цього застосовується sigmoid для забезпечення ймовірностей на кожному пікселі [15]. На виході моделі отримують карту, де кожне значення представляє ймовірність наявності дефекту в конкретному пікселі наявного зображення.

Основна концепція системи виявлення пошкоджень на PCB полягає у тому, що модель фокусується тільки на тих ділянках, де присутні зміни, завдяки чому точність сегментації зображення підвищується. Використання підходу на підставі аналізу різницевого зображення дає змогу моделі виділяти навіть невеликі дефекти, які можуть залишатися непоміченими за прямого аналізу зображення. Схематично алгоритм роботи моделі наведено на рис. 1, де: а – методи Conv 3 – 256 (convolutional layer 3 – 256) для перетворення зображення з триканального наведення на 256-канальне [18]; б – операція Upsample 128 – 32 збільшення просторової роздільності ознак від 256- до 128-канальної; в – операція MaxPool для зменшення розмірності просторових даних, зберігаючи найважливіші ознаки; г – DAAM (Defect Attention Augmentation Model) – модель підсилення механізмів уваги для виявлення дефектів на друкованих платах; д – операція Conv для зменшення одноканальної роздільності з виділенням важливих ознак; е – операція sigmoid для перетворення результату операції (д) на карту ймовірностей [15].

Навчання моделі для сегментації дефектів на PCB розпочинається з підготовки даних. Спершу створюється клас для зберігання пар "зображення-маска". Усі зображення були попередньо підготовлені для навчання моделі. Загалом алгоритм навчання моделі для виявлення пошкоджень на PCB такий:

- на вхід мережі подається зображення;
- маска видає передбачену маску – карту ймовірностей для кожного пікселя;
- порівнюємо передбачення з істинною маскою за допомогою функції втрат;
- обчислюємо похибку та передаємо її назад по мережі, щоб скоригувати ваги.




Рис. 1. Схема алгоритму роботи моделі / Schematic representation of the model algorithm

Результати навчання моделі для виявлення пошкоджень на друкованих платах визначаємо методами: Binary Cross Entropy (BCE) – обчислює різницю між передбаченою ймовірністю та реальною міткою для кожного пікселя; Dice Loss – вимірює схожість між двома масками як множину пікселів; комбінація Dice Loss та BCE.

Навчання моделі для виявлення пошкоджень на друкованих платах відбувалося впродовж 35 хв та 10 епох. Значення похибок і точності повністю задовольняють наші очікування: втрати досить низькі, а точність висока та зростає із кожною епохою навчання моделі для виявлення пошкоджень на друкованих платах. Результати навчання моделі наведено на рис. 2, 3, 4.

Epoch 1/10, Dice: 0.6857, BCE: 0.0419, SegLoss: 0.3638, Accuracy: 0.9994
 Epoch 2/10, Dice: 0.2236, BCE: 0.0008, SegLoss: 0.1122, Accuracy: 0.9997
 Epoch 3/10, Dice: 0.1751, BCE: 0.0007, SegLoss: 0.0879, Accuracy: 0.9998
 Epoch 4/10, Dice: 0.1483, BCE: 0.0006, SegLoss: 0.0744, Accuracy: 0.9998
 Epoch 5/10, Dice: 0.1344, BCE: 0.0005, SegLoss: 0.0675, Accuracy: 0.9998
 Epoch 6/10, Dice: 0.1263, BCE: 0.0005, SegLoss: 0.0634, Accuracy: 0.9998
 Epoch 7/10, Dice: 0.1188, BCE: 0.0005, SegLoss: 0.0597, Accuracy: 0.9999
 Epoch 8/10, Dice: 0.1126, BCE: 0.0005, SegLoss: 0.0565, Accuracy: 0.9999
 Epoch 9/10, Dice: 0.1086, BCE: 0.0005, SegLoss: 0.0545, Accuracy: 0.9999
 Epoch 10/10, Dice: 0.1084, BCE: 0.0005, SegLoss: 0.0545, Accuracy: 0.9999

Рис. 2. Результати навчання моделі / Model training results

Програш у кубиках (Dice Loss) – функція втрат, яку використовують в сегментації зображень для вимірювання подібності між масками сегментації, отриманими за передбачуваними даними, та масками сегментації на підставі реальних даних шляхом кількісного оцінювання їх перекриття.




Рис. 3. Графік Dice Loss / Chart Dice Loss

Бінарна перехресна ентропія BCE (англ. *Binary Cross Entropy*) – це функція втрат, яку використовують в ма-

шинному навчанні для завдань бінарної класифікації даних, що вимірює різницю між прогнозованими ймовірностями та фактичними бінарними мітками. Це карає модель за неправильні прогнози, причому більше значення втрат вказує на гіршу продуктивність, і мінімізується під час навчання для підвищення точності.




Рис. 4. Графік Binary Cross Entropy / Chart Binary Cross Entropy

Тестування моделі проводилось для кількох класів похибок: missing hole, mouse bite, open circuit, short, spur. Результати тестування наведено на рис. 5, 6, 7, 8, 9 відповідно до класу.




Рис. 5. Результат виявлення дефекту "Відсутні отвори" / Result of detection the defect "Missing hole"




Рис. 6. Результат виявлення дефекту "Пошкодження доріжок" / Result of detection the defect "Mouse bite"




Рис. 7. Результат виявлення дефекту "Розімкнений ланцюг" / Result of detection the defect "Open circuit"




Рис. 8. Результат виявлення дефекту "Коротке замикання" / Result of detection the defect "Short"




Рис. 9. Результат виявлення дефекту "Шпори" / Result of detection the defect "Spur"

Застосування запропонованої методики виявлення дефектів друкованих плат на підставі аналізу різницевого зображення та модуля DAAM показало високу ефективність її застосування у сегментації зображень на друкованих платах. Отримані результати показують значну чутливість моделі до локальних змін зображення, зменшення кількості хибних спрацювань та стабільність роботи. Це свідчить про практичну цінність запропонованої методики та її значні переваги порівняно з наявними підходами.

Обговорення результатів дослідження. У роботі [11] проаналізовано застосування згорткових нейронних мереж для автоматичного виявлення дефектів на друкованих платах. Приділено особливу увагу на тренуванні моделі для виявлення пошкоджень на відносно малих наборах даних і вивченню ієрархічних ознак без ручного виділення ознак. Автори зробили висновки, що CNN істотно підвищують загальну точність, зменшують потребу в попередньому обробленні зображення, проте відзначено обмеження у виявленні мікродефектів, що обґрунтовує доцільність розроблення більш чутливої та стійкої архітектури нейронної мережі для виявлення дрібних дефектів на PCB.

У роботі [19] здійснено аналіз удосконаленого підходу на базі повних згорткових мереж (англ. *Fully Convolutional Network*) для сегментації чотирьох типів дефектів PCB. Автори особливу увагу надали інтеграції легкого backbone (MobileNet-V2) та процедур багатоступеневого злиття ознак. Зроблено висновок, що модель виявлення пошкоджень сягає точності 92,86 % за помірних обчислювальних витрат. Проте, автори вказують на те, що існує слабкість локалізації дрібних дефектів, що виправдовує потребу в моделі з кращою деталізацією. Також автори продемонстрували ефективність застосування моделі з низькою потребою обчислювальних ресурсів, що узгоджується з нашим дослідженням щодо розроблення легкої моделі.

У дослідженні [17] автори надали перевагу методам попереднього оброблення (нормалізації, фільтрації шуму, аугментації) зображення і порівнянню архітектур VGG (англ. *Visual Geometry Group*), ResNet, U-Net з огляду на точність та швидкодію. Автори дійшли виснов-

ку, що методи глибинного навчання для тренування моделей значно переважають над класичними методами. Це доводить доцільність використання U-Net архітектури згорткової нейронної мережі для виявлення пошкоджень на PCB, що узгоджується з нашим дослідженням, щодо використання U-Net у моделі для виявлення пошкоджень на PCB. Також автори довели доцільність попереднього оброблення зображень для збільшення точності виявлення пошкоджень, що узгоджується з нашим дослідженням щодо використання методів Гаусового згладжування.

Автори праці [9] навели особливості застосування методів виявлення пошкоджень на PCB із застосуванням удосконаленого Faster-R-CNN у поєднанні з FPN (англ. *Feature Pyramid Network*). Ключову увагу приділено використанню ResNet50 + FPN для одночасного аналізу зображення на різних рівнях деталізації та оптимізації пропорцій фрагментів зображення. Зроблено висновки, що підхід значно покращує виявлення пошкоджень на PCB різного масштабу, особливо дрібних дефектів у складних фонах. Проте, автори відзначають високу обчислювальну складність, що вчергове доводить те, що існує потреба у розробленні методу виявлення пошкоджень на друкованих платах, який буде виявляти дрібні пошкодження та не потребуватиме великих обчислювальних ресурсів.

У роботі [6] наведено результати оптичного та електричного контролю у виробництві друкованих плат. Автори вважають, що контроль якості набуває дедалі більшого значення у виробництві друкованих плат, щоб забезпечити надійність електронного обладнання. За цих обставин для тестування друкованих плат застосовувалися оптичні та електричні методи. Під час електричного контролю випробування літаючим зондом виявили такі типові розриви в електричних ланцюгах друкованих плат, як дефекти розірваного кола та коротке замикання. Згідно з випробуваннями, розриви були спричинені такими дефектами, як травлення, сторонні вклучення та зменшення відстані між провідниками. Вони вважають, що як оптичні, так і електричні підходи до контролю якості друкованих плат здатні зробити системному контролю якості набагато ефективнішою.

У роботі [1] автори показали особливості застосування алгоритму YOLO для виявлення пошкоджень на друкованих платах у реальному часі. Основним предметом дослідження стали масштабування моделі та тренування моделі для виявлення пошкоджень на PCB на великому наборі даних (~11 000 зображень), що дало змогу досягти високої точності (~98, 79 %). Зроблено висновки, що алгоритм YOLO забезпечує відмінну швидкість і точність для великих за розміром дефектів. Автори зазначають, що модель для виявлення пошкоджень на друкованих платах має обмеження за розрізнення дрібних або візуально схожих дефектів (наприклад: spur, mouse bite), через що доцільно розробити або інтегрувати додаткові модулі підсилення уваги до пошкоджень, що узгоджуються з нашим дослідженням щодо розроблення моделі для виявлення пошкоджень на PCB з використанням DAAM.

У праці [7] застосовано skip-connected конволюційного автоенкодера для виявлення та сегментації дефектів на PCB. Особливу увагу автори приділили підходу "відновлення бездефектного" зображення та подальшому виявленню дефектів через різницю між вхід-

ними і реконструйованими кадрами. Автори дійшли висновку, що підхід "відновлення бездефектного" зображення забезпечує високу точність виявлення пошкоджень на РСВ, проте має обмеження в разі виявлення дефектів, що майже не змінюють текстуру або контраст. Їхнє дослідження доводить, що використання конволюційних автоенкодерів покращує точність виявлення пошкоджень, що узгоджується із нашим дослідженням щодо використання skip-connected конволюційного автоенкодера.

Унаслідок обговорення результатів дослідження виявлено, що у проаналізованій літературі помітний брак універсального рішення, яке поєднувало б здатність програмної системи до точного виявлення як великих, так і дрібних пошкоджень на РСВ за обмежених обчислювальних ресурсів та збереження високої швидкодії. Саме тому проведення цього дослідження є доцільним, адже запропонований підхід орієнтований на подолання зазначених обмежень шляхом використання моделі для виявлення пошкоджень на РСВ, яка поєднує U-Net архітектуру нейронної мережі та підсилення уваги до виявлення дефектів.

Отже, внаслідок виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – отримала подальший розвиток методика виявлення пошкоджень на зображеннях друкованих плат, яка ґрунтується на удосконаленій архітектурі сегментаційної мережі з інтегрованим механізмом підсилення уваги до дефектів, що забезпечує підвищену точність сегментації зображень РСВ.

Практична значущість результатів дослідження – результати дослідження використано для розроблення програмного забезпечення з виявлення пошкоджень на друкованих платах у процесі розпізнавання образів, що дає можливість підвищити точність і швидкість перевірки їхніх дефектів за виробничих умов.

Висновки / Conclusions

Розроблено систему виявлення пошкоджень на друкованих платах з використанням моделі підсилення механізмів уваги, яка дала змогу ефективно ідентифікувати дефекти на підставі комбінації масок. За результатами проведеного дослідження можна зробити такі основні висновки.

1. Систематизовано сучасні методи автоматичного виявлення пошкоджень на друкованих платах та проаналізовано їх обмеження, пов'язані з низькою точністю за умов шуму, недостатнього освітлення та наявності дрібних дефектів.
2. Встановлено, що використання класичних методів оброблення зображень є недостатнім для коректного виявлення складних або мінімальних за розмірами пошкоджень (≤ 1000 мкм), що обґрунтовує доцільність застосування глибинних нейронних мереж.
3. Розроблено модель на підставі U-Net-архітектури нейронних мереж з інтеграцією механізму підсилення уваги до пошкоджень, що дає можливість локалізувати дрібні дефекти на РСВ за рахунок ефективного аналізу масок і різницевих зображень РСВ.
4. Проведено тренування моделі за допомогою бібліотеки PyTorch із застосуванням функції втрат CrossEntropy-Loss, завдяки чому досягнуто точності 97 % на тестових даних для більшості класів дефектів, що перевищує показники традиційних моделей.
5. З'ясовано, що точність моделі виявлення пошкоджень друкованих плат дещо знижується в разі оброблення зображень із дефектами складної форми або мінімальних розмірів, що потребує подальшого вдосконалення моделі або розширення навчальної вибірки.

References

1. Adibhatla, V. A., Chih, H.-C., Hsu, C.-C., Cheng, J., Abbod, M. F., & Shieh, J.-S. (2020). Defect Detection in Printed Circuit Boards Using You-Only-Look-Once Convolutional Neural Networks. *Electronics*, 9(9), article ID 1547. <https://doi.org/10.3390/electronics9091547>
2. Akhatova, A. (2019). *PCB defects* [Dataset] Kaggle. URL: <https://www.kaggle.com/datasets/akhatova/pcb-defects>
3. Chen, I-Chun, Hwang, Rey-Chue, & Huang, Huang-Chu. (2023). PCB Defect Detection Based on Deep Learning Algorithm. *Processes*, 11(3), article ID 775. <https://doi.org/10.3390/pr11030775>
4. Chen, X., Wu, Y., He, X., & Ming, W. (2023). A Comprehensive Review of Deep Learning-based PCB Defect Detection. *IEEE Access*, 11, 139017–139038. <https://doi.org/10.1109/access.2023.3339561>
5. Hu, B., & Wang, J. (2020). Detection of PCB Surface Defects With Improved Faster-RCNN and Feature Pyramid Network. *IEEE Access*, 8, 108335–108345. <https://doi.org/10.1109/access.2020.3001349>
6. Kanygina, E. D., Denisova, O. V., & Rastvorova, I. V. (2019). Optical and Electrical Control in Printed Circuit Board Manufacturing. *IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)*, pp. 536–538. <https://doi.org/10.1109/EIConRus.2019.8656918>
7. Khalilian, S., Hallaj, Y., Balouchestani, A., Karshenas, H., & Mohammadi, A. (2020). PCB defect detection using denoising convolutional autoencoders. *2020 International Conference on Machine Vision and Image Processing*, 1–5. <https://doi.org/10.1109/MVIP49855.2020.9187485>
8. Kim, J., Choi, H., & Kim, H. (2021). Printed Circuit Board Defect Detection Using Deep Learning via A Skip-Connected Convolutional Autoencoder. *Sensors*, 21(15), article ID 4968. <https://doi.org/10.3390/s21154968>
9. Leng, Y., & Liu, J. (2025). Improved Faster R-CNN for steel surface defect detection in industrial quality control. *Scientific Reports*, 15(1), article ID 30093. <https://doi.org/10.1038/s41598-025-12740-x>
10. Li, Y., Wang, Y., Lui, J., Wu, K., Abdullahi, H. S., Lv, P., & Zhang, H. (2025). Lightweight PCB defect detection method based on SCF-YOLO. *PLOS ONE*, 20(4), article ID e0318033. <https://doi.org/10.1371/journal.pone.0318033>
11. Mohapatra, S., Kabra, A., Gowda, D. H., Gaonkar, S. S., & Sadhukha, S. (2023). PCB defect detection using CNN-based deep learning. In *Soft Computing for Security Applications*, 363–376. Springer. https://doi.org/10.1007/978-981-99-3608-3_25
12. Rey Otero, I., & Delbracio, M. (2016). Computing an Exact Gaussian Scale-Space. *Image Processing On Line*, 5, 8–26. <https://doi.org/10.5201/ipol.2016.117>
13. Shen, M., Lui, Y., Chen, J., Ye, K., Gao, H., Che, J., Wang, Q., He, H., Lui, J., Wang, Y., & Jiang, Y. (2024). Defect detection of printed circuit board assembly based on YOLOv5. *Scientific Reports*, 14(1), article ID 19287. <https://doi.org/10.1038/s41598-024-70176-1>
14. Tan, S. C., & Kit, S. T. W. (2016). Fast retrievals of test-pad coordinates from photo images of printed circuit boards. *2016 International Conference on Advanced Mechatronic Systems (ICAMechS)*, Melbourne, VIC, Australia, pp. 464–467. <https://doi.org/10.1109/ICAMechS.2016.7813492>
15. Wang, Y., Li, Y., Song, Y., & Rong, X. (2020). The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition. *Applied Sciences*, 10(5), article ID 1897. <https://doi.org/10.3390/app10051897>
16. Xiao, G., Hou, S., & Zhou, H. (2024). PCB defect detection algorithm based on CDI-YOLO. *Scientific Reports*, 14(1), article ID 7351. <https://doi.org/10.1038/s41598-024-57491-3>

17. Zhang, J. (2024). PCB defect image recognition method based on deep convolutional neural network. *Journal of Electronic Testing*, 40, 657–667. <https://doi.org/10.1007/s10836-024-06145-3>
18. Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57(4), article ID 99. <https://doi.org/10.1007/s10462-024-10721-6>
19. Zheng, J., Sun, X., Zhou, H., Tian, C., & Qiang, H. (2022). Printed circuit boards defect detection method based on improved fully convolutional networks. *IEEE Access*, 10, 109908–109918. <https://doi.org/10.1109/access.2022.3214306>

O. V. Fedak, R. A. Melnyk

Lviv Polytechnic National University, Lviv, Ukraine

SYSTEM FOR DETECTING DEFECTS ON PRINTED CIRCUIT BOARDS USING ATTENTION MECHANISM ENHANCEMENT MODEL

A detailed analysis of modern methods and current systems for automatic detection of defects on printed circuit board (PCB) has been performed. Limitations of traditional image processing algorithms were identified, which reduce their effectiveness under complex conditions such as noise, low illumination, or small defects, that are difficult to detect with classical approaches defect detection on printed circuit board. A model was developed that employs the Defect Attention Augmentation Model (DAAM) in combination with deep convolutional neural networks to improve the accuracy of defect localization based on mask and difference image analysis (an image generated by computing the pixel-wise difference between two images in order to highlight changes or detect defects), enabling the detection of even minor defects. The U-Net architecture was used as it provides better extraction of important image regions compared to classic models. The PCB defect detection system was implemented using the PyTorch framework, which allows for the development and training of neural networks. A function for creating difference images was implemented to improve the accuracy of defect detection on printed circuit boards. The difference image creation function enables the identification of changes and anomalies on the PCB surface. Preprocessing of both images was carried out using Gaussian smoothing, which reduces noise in the images. Initial data included defect masks of various classes (missing hole, mouse bite, open circuit, short, spur). Images were pre-annotated and divided by class, and annotation maps were generated for model training. The model was trained over 10 epochs using CrossEntropyLoss function. The results showed an accuracy of 97 % on the test data for most defect classes, while a slight decrease in accuracy (down to 93 %) was observed for defects with complex shapes or minimal sizes ($\leq 1000 \mu\text{m}$), indicating the need for further model improvement or an increase in the training dataset. The PCB defect detection system can be applied in PCB manufacturing for quality control and in other electronics-related industries. This would enhance the quality of PCB production, reduce defective products, and optimize manufacturing processes. The system can also be valuable in research and development goals of creating new quality control technologies.

Keywords: defect detection; printed circuit boards (PCB); deep convolutional neural networks; image segmentation; defect attention augmentation mechanism.