

Визначення дефектів на друкованих електричних платах методом навчання без підкріплення

<https://doi.org/10.31713/MCIT.2024.114>

Владислав Сельоткін
НТУУ "КПІ імені Ігоря Сікорського"
Київ, Україна
vlad.selotkin@gmail.com

Володимир Волощук
НТУУ "КПІ імені Ігоря Сікорського"
Київ, Україна
vl.volodya@gmail.com

Анотація – Контроль якості друкованих плат забезпечується шляхом використання алгоритмів комп'ютерного зору та нейронних мереж для виявлення дефектів, таких як замикання, розриви чи неправильне розташування компонентів. Автоматизовані системи контролю якості дозволяють швидко та точно ідентифікувати дефекти на ранніх етапах виробництва, що мінімізує витрати та забезпечує високу надійність продукції, особливо у критичних галузях, таких як медична та аерокосмічна техніка.

Ключові слова – комп'ютерний зір; визначення дефектів; друковані плати

I. ВСТУП

У сучасному виробництві друкованих електричних плат якість продукції є критичним фактором для забезпечення надійності електронних пристроїв. Дефекти, такі як замикання, розриви чи неправильне розташування компонентів, можуть призвести до несправності пристроїв. Виявлення дефектів на платах на етапі виробництва дозволяє запобігти можливим збоєм та несправностям у майбутньому використанні. Більшість методів контролю якості часто базуються на підходах, що вимагають попередньої розмітки даних, однак у багатьох випадках отримання великих обсягів розмічених даних є дорогою та трудомісткою задачею.

Методи навчання без підкріплення відкривають нові можливості для автоматизованого виявлення аномалій без потреби у розмічених даних. Такі підходи дозволяють виявляти відхилення від норми, спираючись лише на особливості структури даних. У цій статті пропонується дослідити застосування методів навчання без підкріплення для аналізу та ідентифікації аномалій на друкованих електричних платах.

II. ОГЛЯД ДОСЛІДЖЕНЬ

Методи навчання без підкріплення набувають все більшого значення в галузі контролю якості друкованих електричних плат, оскільки вони дозволяють виявляти дефекти без необхідності у великій кількості розмічених даних. Традиційні методи контролю, такі як відповідність шаблонів або

аналіз сірої шкали, вимагають наявності попередньо визначених зразків або стандартних еталонів для порівняння. Вони добре працюють для конкретних типів дефектів, проте їхня ефективність суттєво знижується у випадках, коли кількість або типи дефектів заздалегідь невідомі, або якщо система стикається з новими варіаціями проблем. Крім того, процес отримання та розмітки зразків для традиційних методів може бути дорогим і ресурсозатратним.

Навчання без підкріплення пропонує підхід, при якому модель вивчає статистичні закономірності даних, щоб виявляти відхилення без потреби в чітких позначках дефектів. Такі методи дозволяють адаптуватися до нових типів дефектів та значно зменшують залежність від попереднього досвіду. Моделі, побудовані на цьому принципі, здатні ідентифікувати аномалії як відхилення від нормального патерну, навіть якщо такі дефекти раніше не зустрічалися в навчальному наборі. Це робить їх особливо ефективними для завдань, де важко передбачити всі можливі типи аномалій заздалегідь.

Одним із найпотужніших сучасних підходів до виявлення аномалій є метод PatchCore, який використовує поєднання локальних особливостей зображення для пошуку аномалій[1]. PatchCore об'єднує сильні сторони попередньо навчених моделей та методів зниження розмірності, таких як мета Patch-Encoder, для оцінки локальних відмінностей в області інтересу. Цей метод дозволяє ефективно працювати з великими зображеннями та виділяти лише ті частини, де є відхилення, що суттєво знижує обчислювальні витрати порівняно з класичними методами.

Переваги методів навчання без підкріплення включають:

- Гнучкість до нових дефектів
- Економія ресурсів
- Висока точність при невеликому наборі даних

Таким чином, методи навчання без підкріплення, зокрема PatchCore, є ефективним інструментом для виявлення аномалій у системах перевірки якості друкованих плат [2]. Вони забезпечують високу

точність, гнучкість та значну економію ресурсів, що робить їх переважним вибором у сучасних автоматизованих системах контролю якості.

III. ОПИС ДОСЛІДЖЕННЯ

A. Набір даних

В експериментальних дослідженнях було використано набір даних VisA (Visual Anomaly Dataset) [3]. Цей набір даних призначений для дослідження та оцінки методів виявлення аномалій у візуальних даних. Він створений для вирішення завдань автоматичного виявлення дефектів на основі зображень, що може бути корисним у багатьох виробничих та індустріальних сценаріях, таких як перевірка якості на виробничих лініях. Набір даних містить велику кількість високоякісних зображень різних об'єктів, серед яких присутні як бездефектні зразки, так і зразки з різними видами дефектів.

VisA орієнтований на дослідження в області навчання без підкріплення та навчання з обмеженою кількістю розмічених даних, що робить його корисним для перевірки ефективності алгоритмів виявлення аномалій, які не потребують великих наборів даних з чіткими розмітками. Зображення в VisA охоплюють широкий спектр текстур, геометричних форм та типів дефектів, зокрема 4 набори даних друкованих плат зображені на Рис.1.




Рисунок 1. Приклад даних з набору даних VisA

B. Нейронна мережа PatchCore

PatchCore — це сучасна нейронна мережа для виявлення аномалій та дефектів у зображеннях, що базується на порівнянні локальних патернів. Її основна мета — виявлення відхилень від норми візуальних даних, що робить її ефективним інструментом для застосувань у виробництві та контролі якості. На відміну від класичних методів, які можуть покладатися на глобальні характеристики зображення, PatchCore фокусується на локальних особливостях і шукає аномалії на рівні невеликих патчів (ділянок) зображення.

PatchCore використовує попередньо навчені моделі для вилучення локальних ознак зображення. Ці ознаки являють собою фрагменти зображення (патчі), що відображають текстуру, колір та структуру конкретної ділянки. Оскільки порівняння всіх можливих патчів може бути обчислювально важким, PatchCore застосовує алгоритми вибірки або

зменшення розмірності для вибору найбільш репрезентативних патчів. Це дозволяє зберегти важливі характеристики зображення і водночас зменшити кількість даних, які потрібно порівнювати. Для кожного нового зображення алгоритм порівнює локальні патчі з базою нормальних патчів, які було збережено раніше. Якщо новий патч суттєво відрізняється від нормальних зразків, він позначається як аномалія. PatchCore використовує метрики відстані для оцінки схожості між новими патчами та зразками з бази даних. Чим більша відстань, тим більш ймовірно, що даний патч є аномальним. Після обробки всіх патчів зображення формується теплова карта, яка вказує на ділянки, що найбільше відрізняються від норми. Це дозволяє точно локалізувати аномалії на зображенні. Загальна структура алгоритму представлена на Рис.2.




Рисунок 2. Діаграма нейронної мережі PatchCore

PatchCore відзначається високою ефективністю в задачах виявлення аномалій навіть на малих наборах даних та демонструє чудові результати в порівнянні з іншими підходами у задачах навчання без підкріплення.

IV. РЕЗУЛЬТАТИ

На рівні зображень модель показала високі результати з точністю 87.00%, що вказує на здатність правильно класифікувати більшість зображень як аномальні або нормальні. Прецизійність склала 84.91%, що свідчить про високий відсоток правильно ідентифікованих аномальних зображень серед усіх зображень, класифікованих як аномальні. Водночас повнота досягла 90.00%, що означає, що більшість з усіх аномальних зображень були правильно виявлені. F1-міра, яка поєднує прецизійність і повноту, склала 87.38%, що демонструє загальний збалансований результат.

На рівні пікселів модель показала менш вражаючі результати. Індекс перекриття (IoU) склав 49.85%, що свідчить про обмежену точність у сегментації аномальних областей. Dice коефіцієнт, який є іншою метрикою, що враховує перекриття між передбаченими та реальними областями аномалій, склав 66.54%, що показує середню точність у сегментації на рівні пікселів.

Ці результати демонструють високу ефективність моделі для виявлення аномалій на рівні зображень, проте сегментація аномалій на рівні пікселів вимагає подальшого покращення для досягнення більш високих значень IoU та Dice коефіцієнтів.

Таблиця 1. МЕТРИКИ НА РІВНІ ЗОБРАЖЕНЬ ТА ПІКСЕЛІВ

	Метрики	
	Рівень зображення	Точність
Прецизійність		0.849
Повнота		0.9
F1-міра		0.8738
Рівень пікселів	IoU (Індекс перекриття)	0.4985
	Dice коефіцієнт	0.6654

V. ВИСНОВКИ

Дослідження показало високу ефективність методів навчання без підкріплення для виявлення аномалій на друкованих платах, зокрема моделі PatchCore. Водночас існує необхідність подальшого

вдосконалення декількох аспектів, щоб підвищити якість результатів. Для досягнення більш високої точності виявлення аномалій на рівні пікселів слід збільшити роздільну здатність отриманих локальних ознак. Це дозволить точніше ідентифікувати дрібні дефекти, такі як мікротріщини чи непомітні зміни текстури, які не завжди можуть бути чітко відображені при нинішньому рівні деталізації ознак. Для забезпечення більш стабільної роботи системи необхідно підвищити стійкість моделі до таких факторів, як шум, дефекти камер або зміни умов освітлення. Це дозволить зменшити кількість помилкових спрацьовувань та підвищити надійність виявлення аномалій у реальних умовах виробництва.

Отже, оптимізація моделей шляхом покращення роздільної здатності та стійкості до шуму є ключовим кроком для досягнення більшої точності та стабільності у виявленні дефектів друкованих плат.

ЛІТЕРАТУРА

- [1] Roth, K., Pemula, L., Zepeda, J., Scholkopf, B., Brox, T., & Gehler, P. (2022). Towards total recall in industrial anomaly detection. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). <https://doi.org/10.1109/cvpr52688.2022.01392>
- [2] Zipfel, J., Verworn, F., Fischer, M., Wieland, U., Kraus, M., & Zschech, P. (2023). Anomaly detection for industrial quality assurance: A comparative evaluation of unsupervised deep learning models. *Computers & Industrial Engineering*, 177, 109045. <https://doi.org/10.1016/j.cie.2023.109045>
- [3] Zou, Y., Jeong, J., Pemula, L., Zhang, D., & Dabeer, O. (2022). SPOT-the-Difference Self-supervised pre-training for anomaly detection and segmentation. In *Lecture notes in computer science* (pp. 392–408). https://doi.org/10.1007/978-3-031-20056-4_23