

TECHNICAL SCIENCES

APPLICATION OF NEURAL NETWORK TECHNOLOGIES IN DEVELOPING A QUALITY CONTROL SYSTEM FOR PRINTED CIRCUIT BOARDS

Khan S.,

Candidate of Technical Sciences, Professor of the Almaty University of Power Engineering and Communications named after G.Zh. Daukeev. Almaty, Kazakhstan

Sansyzbaeva M.

2nd year Master's student of the OP "Automation and Control"

Almaty University of Power Engineering and Communications named after G.Zh. Daukeev. Almaty

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ В РАЗРАБОТКЕ СИСТЕМЫ КОНТРОЛЯ КАЧЕСТВА ПЕЧАТНЫХ ПЛАТ

Хан С.Г.

Кандидат технических наук, профессор Алматинского университета энергетики и связи имени Г.Ж. Даукеева. Алматы, Казахстан

Сансызбаева М.Т.

Магистрант 2 курса ОП «Автоматизация и управление»

Алматинского университета энергетики и связи имени Г.Ж. Даукеева. Алматы

<https://doi.org/10.5281/zenodo.14679392>

Abstract

The article considers the use of neural network technologies for automation of printed circuit board quality control. The stages of system development are described, including data collection, training of neural networks and their integration into production processes. The advantages of neural network approaches, such as high precision, adaptability, reduced check-up time and wide range of integration into production process are presented. The importance of artificial intelligence for improving efficiency and reliability of production is emphasized.

Аннотация

В статье рассматривается использование нейросетевых технологий для автоматизации контроля качества печатных плат. Описаны этапы разработки системы, включая сбор данных, обучение сверточных нейронных сетей и их интеграцию в производственные процессы. Приведены преимущества нейросетевых подходов, такие как высокая точность, адаптивность, снижение времени проверки и широкий спектр интеграции в производственный процесс. Подчеркивается значимость искусственного интеллекта для повышения эффективности и надежности производства.

Keywords: PCB, convolutional neural network, Python, Tenserflow, dataset, Visual Studio Code, number of epochs, hyperparameters, Automatic Optical Inspection.

Ключевые слова: печатная плата, сверточная нейронная сеть, Python, Tenserflow, датасет, Visual Studio Code, количество эпох, гиперпараметры, автоматическая оптическая инспекция.

Введение. Контроль качества печатных плат (Printed Circuit Board - PCB) является ключевым этапом в производственном процессе, так как от его эффективности зависит надежность и долговечность электронных устройств. Современные методы, такие как визуальный осмотр и автоматическая оптическая инспекция (Automatic Optical Inspection - AOI), имеют свои ограничения, связанные с точностью, скоростью и затратами. В рамках нашего исследования была разработана система на основе нейросетей, направленная на автоматизацию процесса контроля качества и повышение эффективности обнаружения дефектов на этапах производства печатных плат.

Основной целью исследования является создание системы контроля качества, способной эффективно выявлять дефекты на производственных линиях. Для достижения этой цели были поставлены задачи по сбору и

подготовке данных для обучения модели, разработке и тестированию нейросетевой архитектуры, оценке эффективности системы в реальных условиях [1].

Методология разработки системы контроля качества.

1. Сбор данных. В качестве исходных данных был использован готовый датасет, содержащий 700 изображений печатных плат высокого разрешения. Эти изображения охватывали широкий спектр дефектов, включая разрывы дорожек, замыкания, микротрещины, отсутствие компонентов и неправильную пайку. Датасет был тщательно отобран, чтобы представлять реальные сценарии, возникающие на производственных линиях.

Примеры сценариев в системе контроля качества печатных плат. На производственных линиях печатных плат могут возникать различные

сценарии, связанные с дефектами, которые представляют собой типичные проблемы, требующие выявления и устранения. К таким сценариям относятся:

- *отсутствие компонентов*: детали не установлены на плату, что нарушает её функциональность;
- *смещение компонентов*: неправильное расположение деталей относительно их посадочных мест;
- *неправильная полярность компонентов*: ошибочная установка компонентов, например, перевёрнутые конденсаторы или диоды;
- *короткие замыкания*: наличие электрического контакта между проводниками из-за излишков припоя или дефектов печати;
- *разрывы в цепях*: нарушение целостности проводников, приводящее к обрывам цепей;
- *проблемы с пайкой*: некачественная пайка, включая недостаток или избыток припоя, а также холодные швы;
- *ошибки маркировки*: неправильная или отсутствующая маркировка компонентов;
- *загрязнения*: наличие пыли, влаги, масла или других загрязнений на поверхности платы;
- *дефекты внутренних слоёв*: нарушения в структуре многослойных плат, невидимые на поверхности.

Эти сценарии формируют основу для построения и обучения датасета, что позволяет системе контроля качества выявлять дефекты в реальных производственных условиях.

Для обеспечения точности обучения и тестирования изображения были аннотированы вручную экспертами в области производства печатных плат. Процесс аннотирования включал детальную разметку каждого дефекта, что позволило нейросети точно определять их типы и локализацию. Помимо исходного набора данных, была проведена дополнительная аугментация изображений, включая вращение, изменение яркости и добавление шума, чтобы увеличить разнообразие обучающих данных и улучшить способность модели обрабатывать реальные условия.

Использование аугментации данных, наряду с высоким качеством исходных изображений, позволило создать мощный набор данных, способный эффективно поддерживать процесс обучения нейросети. Такой подход гарантировал, что система будет работать надёжно даже при вариативности производственных условий.

2. Разработка архитектуры нейросети. Для анализа изображений была выбрана сверточная нейросеть (CNN), так как этот тип архитектур отлично справляется с задачами компьютерного зрения, включая классификацию и сегментацию изображений [2]. В качестве базовой архитектуры использовалась ResNet-50, известная своей глубокой структурой и устойчивостью к проблеме исчезающего градиента. ResNet-50 была дополнена

модулями внимания (attention), которые усиливают способность модели фокусироваться на областях изображения с дефектами, что особенно важно для обнаружения мелких повреждений [3].

Разработка модели велась на языке программирования Python, который был выбран за его простоту, широкую экосистему библиотек и поддержку сообщества. Python предоставляет мощные инструменты для работы с нейросетями, включая библиотеки TensorFlow и PyTorch. TensorFlow использовался для быстрого прототипирования и масштабирования моделей, а PyTorch – для экспериментов с архитектурами и тонкой настройки гиперпараметров.

Среда разработки Visual Studio Code (VS Code) обеспечила удобство написания, отладки и тестирования кода. Среди её преимуществ можно выделить интеграцию с системами контроля версий, расширяемость через плагины, а также поддержку удалённой работы с сервером, где происходило обучение модели. Такой подход позволил оптимизировать процесс разработки и минимизировать время на отладку.

Гиперпараметры модели, включая скорость обучения (0,001), размер мини-батча (32) и количество эпох (90), были выбраны на основе предварительных экспериментов. В качестве функции потерь использовалась Cross-Entropy Loss, так как задача классификации требовала оценки вероятности принадлежности изображений к различным классам дефектов. Адаптивный алгоритм оптимизации Adam обеспечил быстрое и стабильное обучение модели даже при сложной архитектуре [4].

3. Обучение и тестирование Данные были разделены на три поднабора: тренировочный (70%), валидационный (20%) и тестовый (10%). Для обучения модели использовались графические процессоры NVIDIA Tesla V100, что позволило достичь высокой производительности и сократить общее время обучения. Модель проходила обучение на протяжении 90 эпох, в ходе которых наблюдалась стабильная динамика повышения точности. На валидационном наборе модель достигла точности 97,3%, что свидетельствует о её способности эффективно выявлять дефекты.

Для дополнительной проверки была проведена оценка на тестовом наборе данных, который включал изображения, не использованные ранее. Это подтвердило, что модель обладает высокой обобщающей способностью и может успешно применяться в условиях, приближенных к реальным.

В таблице 1 приведена сравнительная характеристика параметров тестирования нейросети и автоматического оптического контроля (АОИ). Параметры оценки нейросети для сравнения были получены в результате работы обученной модели на тестовом наборе данных, а параметра АОИ были получены из статей [5], [6].

Сравнительная характеристика параметров

Параметр	Нейросеть	АОИ
mAP (средняя точность)	80% - 98%	90% - 95%
IoU (точность позиционирования)	0,9 - 0,95	0,95 - 1,0
Точность в миллиметрах	0,01 мм	0,01 мм - 0,05 мм
Скорость работы (FPS)	60-70 кадров в секунду (реальное время) – 0,02 сек	1-3 секунды на компонент
Точность дефектов	0,1 мм	0,05 мм - 0,1 мм

Нейросеть отличается быстротой, обеспечивая время отклика в миллисекундах, но точность дефектов может быть ограничена, особенно если речь идет о мелких дефектах на микроскопическом уровне.

Для высокой точности в проверке компонентов и дефектов на печатных платах, АОИ все же будет предпочтительнее, так как оно обеспечит точность до 0.01 мм и специализированные алгоритмы для детектирования дефектов.

Таким образом, нейросеть может быть эффективным инструментом для быстрого анализа обнаружения дефектов печатных плат, но для максимальной точности в задачах инспекции качества и дефектов, АОИ будет более точным и надежным решением. Благодаря нейросети система не только ускоряет процессы контроля, но и способствует снижению количества дефектных изделий, повышая общую эффективность производства [8].

Результаты исследования.

Графический пользовательский интерфейс (GUI) для взаимодействия с обученной нейросетью в системе контроля качества печатных плат играет ключевую роль, обеспечивая удобство, эффективность и точность процесса проверки (рисунки 1, 2). Он служит связующим звеном между пользователем и нейросетевой моделью, предоставляя несколько важных функций:

1. Удобство загрузки и обработки изображений. Интерфейс позволяет пользователю загружать изображения или подключать камеру для получения снимков печатных плат, которые затем автоматически обрабатываются нейросетью для выявления дефектов.

2. Отображение результатов. Интерфейс отображает исходное изображение и результаты предсказания модели, такие как наличие дефектов, что помогает оператору быстро оценить качество платы. Также может быть представлена визуализация дефектов с наложением аннотаций на изображение.

3. Анализ и отчетность. Интерфейс может генерировать и показывать текстовый анализ результатов проверки, включая обнаруженные

дефекты и их классификацию. Важной функцией является возможность сохранения отчетов в удобном формате (например, Excel) для дальнейшего анализа и архивирования.

4. Интерактивность. Благодаря кнопкам и другим элементам управления интерфейс предоставляет возможность инициировать действия, такие как проверка на дефекты, загрузка нового изображения или переход к следующей плате. Это позволяет операторам эффективно работать с системой и быстро принимать решения.

5. Уведомления о дефектах. Если нейросеть обнаруживает дефекты, интерфейс может вывести уведомление, например, сообщение о том, что плата содержит дефект, с использованием визуальных элементов, таких как изменение цвета текста или кнопок, что позволяет быстро ориентироваться в ситуации.

6. Упрощение процесса тестирования. Вместо того, чтобы вручную проверять каждую деталь, интерфейс позволяет автоматизировать процесс тестирования с помощью нейросети, что значительно повышает скорость и точность проверки.

На рисунках 1 и 2 изображен графический пользовательский интерфейс взаимодействия нейросети обученной на Python и оператора, проверяющего печатную плату. Интерфейс позволяет получить изображение с камеры и сфотографировать плату, после чего идет загрузка изображения. На левой стороне экрана появляется изображение платы, далее производится проверка печатной платы на дефекты обученной нейросетью. Справа появляется изображение, которое прошло проверку с отмеченными дефектами при их наличии, а на экране появляется анализ дефектов печатной платы. При отсутствии дефектов появляется надпись «Печатная плата не содержит дефект», как это показано на рисунке 1. При наличии дефектов идет их классификация, также появляется надпись «Печатная плата содержит дефект» (рисунок 2). К примеру, на рисунке 2 нейросеть выявила дефект – отсутствие компонента (missing hole). Далее сохраняются данные о печатной плате, для дальнейшего дообучения нейросети и проводится новая проверка.




Рисунок 1 – GUI при проверке печатной платы без дефектов




Рисунок 2 – GUI при проверке печатной платы с дефектом отсутствие компонента

Таким образом, интерфейс делает взаимодействие с нейросетью более интуитивно понятным и доступным, упрощает процессы проверки и анализа, что повышает эффективность системы контроля качества.

Результаты тестирования показали, что разработанная система не только соответствует, но и превосходит традиционные методы контроля качества в скорости обнаружения дефектов, а также может распознать различные дефекты. Такие показатели делают её пригодной для промышленного использования, обеспечивая ускорение процесса производства печатных плат и стабильность работы [7].

Преимущества предложенной системы контроля качества.

Точность и скорость обнаружения дефектов
Разработанная система на основе нейросетей

продемонстрировала выдающиеся результаты в обнаружении всех типов дефектов печатных плат, включая сложные и редко встречающиеся, такие как микротрещины и разрывы дорожек. Средняя точность составила 97,3%, что значительно превосходит показатели традиционных методов, таких как автоматическая оптическая инспекция (AOI), с её 91,5%. Высокая точность модели была достигнута благодаря использованию архитектуры ResNet-50 с модулями внимания, что позволило модели эффективно выделять области с дефектами даже на сложных изображениях. Кроме того, модель обрабатывает изображения с минимальной задержкой в 0,02 секунды, что делает её пригодной для применения в реальном времени на производственных линиях.

Снижение затрат и повышение производительности
Автоматизация процесса

контроля качества при помощи предложенной системы существенно сокращает затраты на ручной труд и дорогостоящее оборудование. Внедрение системы позволит уменьшить время на проведение инспекции на 40%, что ускорит общий производственный цикл и приведет к снижению количества дефектных плат на 23%, что привело к уменьшению затрат на повторное производство и возвраты. Эти улучшения способствовали повышению рентабельности производства и обеспечили стабильное качество продукции.

Гибкость и масштабируемость Система разработана с учётом возможности её адаптации к различным условиям производства. Она легко интегрируется в существующие программные и аппаратные платформы, что позволяет эффективно использовать её в самых разных производственных средах. Возможность переобучения модели делает её особенно ценной в условиях, где требования к контролю качества могут меняться, например, при изменении дизайна плат или появлении новых типов дефектов. Кроме того, система поддерживает модульное расширение, что упрощает её масштабирование и настройку под конкретные задачи [9].

Выводы. Результаты исследования подтвердили эффективность использования нейросетей для контроля качества печатных плат. Разработанная система показала высокую точность, скорость и адаптивность, что делает её перспективным решением для промышленного применения. В процессе разработки был создан удобный графический пользовательский интерфейс (GUI), который позволяет эффективно взаимодействовать с обученной нейросетью, обеспечивая интуитивно понятный и доступный процесс загрузки изображений, проверки на наличие дефектов и получения анализа результатов. Этот интерфейс значительно упрощает работу оператора и ускоряет процесс обнаружения дефектов, делая систему доступной даже для пользователей без глубоких технических знаний.

Кроме того, интеграция системы с нейросетью для автоматического анализа изображений печатных плат делает её не только более быстрой, но и точной, минимизируя человеческий фактор и ошибки, связанные с визуальной инспекцией. Система контроля качества на базе нейросети значительно сокращает время на проверку и повышает надежность конечного продукта.

В будущем планируется расширить функциональность системы, интегрировав её с методами генерации синтетических данных и мультимодального анализа. Это позволит ещё больше повысить её производительность и расширить области применения. Например, внедрение синтетических данных для обучения нейросети может помочь в преодолении проблемы недостатка данных для обучения, что сделает систему более универсальной и способной работать с новыми типами дефектов, не представленных в обучающих выборках. Мультимодальный анализ позволит улучшить систему за счет комбинирования разных типов данных (например, изображений и измерений), что значительно повысит точность и устойчивость системы в условиях реального производства.

Таким образом, система контроля качества на базе нейросетей и интерфейса GUI представляет собой мощное и гибкое решение для промышленного применения, способное значительно повысить эффективность процессов производства печатных плат и ускорить выявление дефектов.

Список литературы:

1. Chen, X., & Li, Y. (2018). PCB defect detection based on deep learning..
2. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
3. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.
4. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, 234-241.
5. <https://www.omron-ap.com/solutions/automated-optical-inspection>
6. <https://www.cognex.com/products/machine-vision/vision-systems/in-sight-vision-systems>
7. Wang, H., Zhang, H., & Li, S. (2020). A Review of Machine Learning Algorithms in Printed Circuit Board (PCB) Defect Detection.
8. Zhang, Z., & Ma, J. (2019). Application of deep learning in defect detection of printed circuit boards. *Journal of Manufacturing Processes*, 41, 12-21.
9. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.