



УДК 004.932.2  
<https://doi.org/10.37661/1816-0301-2024-21-3-63-79>

Оригинальная статья  
Original Article

## Гибридный контроль дефектов печатных плат

В. В. Венгеренко<sup>✉</sup>, А. В. Инютин

*Объединенный институт проблем информатики  
Национальной академии наук Беларуси,  
ул. Сурганова, 6, Минск, 220012, Беларусь  
✉E-mail: vengerenko@lsi.bas-net.by*

### Аннотация

**Цели.** Предлагается гибридный подход к задаче поиска и классификации дефектов печатных плат. Рассмотрены ключевые факторы и тенденции в проектировании и производстве печатных плат. Актуальность исследования определяется использованием новых материалов и технологий производства.

**Методы.** Для решения поставленной задачи применяется гибридный подход, основанный на алгоритме сравнения с эталоном и использовании семейства нейросетевых моделей обнаружения объектов YOLO.

**Результаты.** Проведено обучение моделей на публичных наборах изображений печатных плат с шестью классами дефектов, выполнена оценка точности общепринятыми метриками.

**Заключение.** Эксперименты показали, что нейросетевая архитектура YOLOv8 имеет высокую точность детекции дефектов, низкую чувствительность к качеству изображений, наличию надписей и графических объектов на печатной плате, но низкое качество обучающих выборок накладывает ограничения на использование только нейронных сетей для поиска дефектов. Предлагается гибридный подход для повышения качества контроля дефектов за счет применения разных методов в зависимости от оценки качества анализируемых изображений.

**Ключевые слова:** математическая морфология, контроль дефектов, печатные платы, детекторы объектов, ограничивающие прямоугольники, нейронные сети, сравнение с эталоном

**Для цитирования.** Венгеренко, В. В. Гибридный контроль дефектов печатных плат / В. В. Венгеренко, А. В. Инютин // Информатика. – 2024. – Т. 21, № 3. – С. 63–79.  
<https://doi.org/10.37661/1816-0301-2024-21-3-63-79>

**Конфликт интересов.** Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию | Received 22.07.2024

Подписана в печать | Accepted 22.08.2024

Опубликована | Published 30.09.2024

# Hybrid inspection of printed board defects

Vadim V. Vengerenko<sup>✉</sup>, Alexander V. Inyutin

*The United Institute of Informatics Problems  
of the National Academy of Sciences of Belarus,  
st. Surganova, 6, Minsk, 220012, Belarus*

<sup>✉</sup>E-mail: [vengerenko@lsi.bas-net.by](mailto:vengerenko@lsi.bas-net.by)

## Abstract

**Objectives.** A hybrid approach to the problem of searching and classifying defects in printed circuit boards (PCB) is proposed. Key factors and trends in the design and production of PCBs are considered. The relevance of the study is determined by the use of new materials and production technologies.

**Methods.** A hybrid approach based on the algorithm of comparison with reference and the use of the YOLO family of neural network models for detecting objects is used to solve the problem.

**Results.** Models were trained on public sets of PCB images with six classes of defects, and their accuracy was assessed using generally accepted metrics.

**Conclusion.** Experiments have shown that the YOLOv8 neural network architecture has high accuracy of defect detection, low sensitivity to image quality, presence of text and graphic objects on the PCB, but the low quality of training datasets imposes restrictions on the use of only neural networks for defect detection. It is proposed to use a hybrid approach to improve the quality of defect inspection by applying different methods depending on the quality assessment of the analyzed images.

**Keywords:** mathematical morphology, inspection of defects, printed circuit boards, object detection, bounding boxes, neural networks, comparison with reference

**For citation.** Vengerenko V. V., Inyutin A. V. *Hybrid inspection of printed board defects*. Informatika [Informatics], 2024, vol. 21, no. 3, pp. 63–79 (In Russ.). <https://doi.org/10.37661/1816-0301-2024-21-3-63-79>

**Conflict of interest.** The authors declare of no conflict of interest.

**Введение.** Существует несколько ключевых факторов, которые стимулируют мировой рынок печатных плат в настоящее время и будут стимулировать его в течение следующих пяти лет<sup>1, 2</sup>:

- развертывание беспроводных сетей 5G, что потребует создания большого количества сетевой инфраструктуры и беспроводного оборудования;
- разработка приборов, машин и устройств интернета вещей (IoT);
- разработка модулей управления двигателями и аккумуляторной батареей электромобилей (EV), а также электронных блоков и дисплеев всех типов автомобилей;
- внедрение усовершенствованных систем помощи водителю (Advanced Driver Assistance Systems, ADAS) для предотвращения столкновений и автоматической парковки. Такие системы используют набор камер, радаров, лидаров и ультразвуковых датчиков, а также сложные печатные платы высокой плотности;
- развертывание источников возобновляемой энергии, таких как солнечные фотоэлектрические системы и ветряные турбины;
- производство современной техники и систем связи для подразделений обороны и аэрокосмической промышленности, требующих специализированных, высокопроизводительных и высоконадежных печатных плат;
- разработка современных медицинских устройств для диагностики, терапии и дистанционного мониторинга пациентов;
- широкое развертывание дата-центров с высокопроизводительными серверами и коммутаторами для облачных вычислений, которые требуют самых современных печатных плат.

<sup>1</sup>What is the PCB Market Situation Now? (Update 2023) [Electronic resource]. – Mode of access: <https://www.raypcb.com/pcb-market/>. – Date of access: 07.05.2024.

<sup>2</sup>The Global Printed Circuit Board Market: Key Insights, Forecasts, & Growth Outlook [Electronic resource]. – Mode of access: <https://www.mktpcb.com/pcb-industry-statistics-trends-infographic/>. – Date of access: 07.05.2024.

Системы контроля топологии печатных плат могут использовать как контактные, так и бесконтактные методы [1–7]. Системы, основанные на контактных методах, касаются щупами контактных площадок и проверяют соответствие электрических связей между ними. В результате обнаруживаются обрывы (open) и короткие замыкания (short). С помощью контактного метода принципиально не могут быть найдены такие дефекты, как островки меди (spurious copper), выступы (spur) и вырывы (mousebite) на дорожках, проколы (pin-hole), отклонения минимальной ширины проводника (conductor too thin) и расстояния между проводниками (conductor too close). Увеличение сложности печатной платы приводит к значительному усложнению контроля. Бесконтактные методы контроля печатных плат делятся на оптические, рентгеновские, ультразвуковые, термические и др. Зачастую при производстве печатных плат применяется сразу несколько методов контроля, например контактный, оптический и рентгеновский.

В настоящее время за рубежом выпускаются автоматизированные системы контроля качества печатных плат. Их ведущими производителями сегодня являются компании Cognex Corporation, Gardien Services Inc., Manncorp Inc., Nordson YESTECH Inc., Omron Electronics LLC, Vision Engineering Inc, ViTrox Corp Bhd и Iбiden.

Актуальность задачи поиска дефектов печатных плат обусловлена следующими тенденциями в их проектировании и производстве [2]:

- использованием соединений высокой плотности (High-Density Interconnect, HDI), что выражается в более плотной разводке печатных плат и уменьшении размера контактных площадок. Отверстия для соединений между слоями могут иметь размер менее 150 мк. Однако существует мнение, что уменьшение шага выводов компонентов фактически достигло своих пределов: 0,65 и 0,3 мм для компонентов, выполненных по технологии PBGA (Plastic Ball Grid Array) и QFP (Quad Flat Package) соответственно. При этом минимальный шаг выводов компонентов FBGA (Fine-pitch BGA) равен 0,3 мм и может уменьшиться до 0,15 мм;
- сочетанием гибких схем и жестких секций на одной печатной плате, которое позволяет осуществлять трехмерную компоновку внутри устройств;
- производством растягивающихся схем, основанных на новых проводящих материалах и методах изготовления, которые позволяют разрабатывать гибкие носимые устройства;
- использованием низкотемпературной керамики совместного обжига (Low Temperature Co-fired Ceramic, LTCC) для высокотермостойких печатных плат, которые могут работать в условиях агрессивной среды в оборонных, аэрокосмических и автомобильных системах;
- выпуском печатных плат с изолированной металлической подложкой (Insulated Metal Substrate, IMS) для эффективного отвода тепла от мощных компонентов;
- внедрением встроенных пассивных элементов (например, конденсаторов) внутрь печатной платы, что дает возможность более эффективно интегрировать компоненты по сравнению с поверхностным монтажом;
- применением аддитивной струйной или аэрозольной печати проводников, позволяющей упростить быстрое прототипирование и настройку печатных плат в ходе разработки;
- расположением выводов под корпусом компонентов;
- интеграцией искусственного интеллекта и машинного обучения для обнаружения дефектов и внедрением принципов Индустрии 4.0 для анализа данных, спрос на высокоскоростной и точный контроль.

В статье предлагается гибридный подход к оптическому контролю дефектов печатных плат, использующему сравнение с эталонным изображением [10] и нейросетевые архитектуры YOLOv8.

**Анализ подходов к детекции объектов.** Модели детекции (обнаружения) объектов на основе глубокого обучения с использованием сверточных нейронных сетей (СНС, или Convolutional Neural Network, CNN) и трансформеров сейчас играют ключевую роль в развитии этой области. Такие модели могут предоставить существенную информацию для семантического понимания изображений и видео. Среди многочисленных примеров их применения стоит отметить поддержку беспилотных автомобилей для безопасной навигации в пробках, распознавание лиц, анализ поведения человека, медицинскую визуализацию, робототехнику, общие методы обработки изображений, приложения дистанционного зондирования.

Основой детекторов объектов служат СНС. Основная цель такой сети – извлекать особенности из изображений перед отправкой их на дальнейшие этапы, например локализацию. Существует несколько стандартных СНС, используемых детекторами объектов, включая VGGNets, ResNets и EfficientNets, которые предварительно обучены для задач классификации.

Поля привязки (anchor boxes) представляют собой заранее определенную коллекцию ограничивающих прямоугольников (bounding boxes) с выбранной шириной и высотой, которые отражают ширину и высоту объектов в наборе обучающих данных. Разумеется, они также включают в себя различные соотношения сторон и масштабы, найденные в наборе данных. При обнаружении заранее определенные поля привязки располагаются на изображении в виде мозаики. Более того, на каждом изображении постоянно предлагаются одни и те же области привязки. Вместо прогнозирования прямоугольников сеть прогнозирует вероятность и другие атрибуты, такие как фон, пересечение над объединением (Intersection over Union, IoU) и смещения для каждого мозаичного поля привязки. Она возвращает уникальную коллекцию прогнозов для каждого установленного поля привязки. Использование полей привязки позволяет сети обнаруживать несколько объектов, объекты разных масштабов и перекрывающиеся объекты [9]. При обнаружении объектов детекторы на основе привязки определяют поля привязки в каждой позиции на карте объектов. Сеть прогнозирует вероятность появления объектов в каждом поле привязки, а затем подгоняет размер полей привязки в соответствии с объектом. Детекторы с использованием привязки обычно делятся на двухэтапные на основе предложений и одностадийные без предложений. Привязки служат эталонами для регрессии и кандидатами на классификацию для прогнозирования предложений для двухэтапных детекторов и окончательных ограничивающих прямоугольников для одностадийных детекторов.

Алгоритмы обнаружения объектов на основе областей были одними из наиболее широко используемых методов обнаружения объектов на изображениях. Двухэтапные методы являются производными от методов R-CNN (Region-based CNN), которые извлекают области интереса (Regions of Interest, RoI) с использованием метода выборочного поиска, а затем классифицируют эти области и выполняют их регрессионный анализ. Faster R-CNN является наиболее известным двухэтапным детектором на основе привязки. Впоследствии было представлено множество моделей для улучшения его характеристик, например Mask R-CNN.

Одностадийные детекторы на основе привязки характеризуются прежде всего эффективностью вычислений и временем выполнения. Такие детекторы напрямую классифицируют предопределенные поля привязки и выполняют их регрессионный анализ вместо использования областей интереса. SSD (Single Shot MultiBox Detector) стал первым известным одностадийным детектором объектов, основанным на привязке. Главной проблемой, с которой сталкиваются одностадийные детекторы на основе привязки, является дисбаланс между положительными и отрицательными образцами. Для решения возникшей проблемы было реализовано несколько подходов и механизмов, таких как уточнение и сопоставление привязок, обучение с нуля, многоуровневое объединение контекстной информации, обогащение и выравнивание признаков, а также разработаны новые функции потерь и архитектуры.

YOLOv8 – это современная модель классификации изображений, сегментации экземпляров и обнаружения объектов без привязки, разработанная Ultralytics [9]. Модели YOLOv8 можно обучать на больших наборах данных и запускать на различных аппаратных платформах. Одной из ключевых особенностей YOLOv8 является расширяемость. YOLOv8 поддерживает все предыдущие версии YOLO, что позволяет легко переключаться между различными версиями и сравнивать их производительность. YOLO захватывает полное изображение в одном экземпляре, а затем прогнозирует координаты ограничивающих прямоугольников и вероятности классов одной сетью за одну оценку.

Развитием идеи обнаружения объектов является введение угла для ограничивающих прямоугольников, чтобы учитывать ориентацию искомого объекта на изображении. Этот подход называется ориентированным обнаружением объектов. Он позволяет точнее находить объекты

на изображении<sup>3</sup>. Ограничивающие прямоугольники в таком случае также называются ориентированными (Oriented Bounding Boxes, OBB). Для моделей YOLOv8 OBB в файлах разметки один ориентированный ограничивающий прямоугольник описывается меткой класса и нормированными координатами всех вершин<sup>4</sup>.

**Наборы изображений для экспериментов.** Для проведения экспериментов были выбраны такие общедоступные наборы изображений, как DeepPCB<sup>5</sup> и синтетический набор изображений дефектов печатных плат PCB Defect Dataset, опубликованный Открытой лабораторией по взаимодействию человека и робота Пекинского университета (The Open Lab on Human Robot Interaction of Peking University)<sup>6</sup>.

Набор изображений DeepPCB содержит 1500 пар бинарных изображений, каждая из которых состоит из эталонного изображения без дефектов и выровненного тестируемого изображения с аннотациями, включающими позиции шести наиболее распространенных типов дефектов печатных плат: обрыв, короткое замыкание, выступ, вырыв, прокол и островок. Изображения получены с помощью ПЗС-матрицы с линейным сканированием и разрешением около 48 пикселей на 1 мм. Изображения, размер которых составляет 640×640 пикселей, получены путем деления исходных эталонов и тестируемых изображений размером около 16 000×16 000 пикселей и выровнены с помощью техники совмещения изображений.

На одном изображении присутствуют несколько дефектов разных классов. Пример тестируемого изображения и соответствующего ему эталона из набора данных DeepPCB приведен на рис. 1.




Рис. 1. Пример тестируемого изображения (a) и соответствующего ему эталона (b)

*Fig. 1. Example of a tested image (a) and its corresponding reference (b)*

Для проведения экспериментов с моделью YOLOv8n использован указанный набор данных уже с примененными к нему техниками аугментации<sup>7</sup>, которые включают следующие операции:

<sup>3</sup>OBB – Ultralytics YOLO Docs [Electronic resource]. – Mode of access: <https://docs.ultralytics.com/tasks/obb/>. – Date of access: 11.07.2024.

<sup>4</sup>Oriented Bounding Box (OBB) Datasets Overview – Ultralytics YOLO Docs [Electronic resource]. – Mode of access: <https://docs.ultralytics.com/datasets/obb/>. – Date of access: 11.07.2024.

<sup>5</sup>A PCB defect dataset [Electronic resource]. – Mode of access: <https://github.com/tangsanli5201/DeepPCB>. – Date of access: 11.07.2024.

<sup>6</sup>PCB Defects [Electronic resource]. – Mode of access: <https://www.kaggle.com/datasets/akhatova/pcb-defects/data>. – Date of access: 11.07.2024.

<sup>7</sup>DeepPCB Image Dataset [Electronic resource]. – Mode of access: <https://universe.roboflow.com/tack-hwa-wong-zak5u/deeppcb-4dhir/dataset/5>. – Date of access: 11.07.2024.

- вертикальный и горизонтальный поворот;
- поворот на  $90^\circ$  по часовой стрелке, против часовой стрелки и вверх ногами;
- обрезку изображения с минимальным масштабированием 0 % и максимальным масштабированием 20 %;
- поворот между  $-15^\circ$  и  $+15^\circ$ ;
- сдвиг  $\pm 15^\circ$  по горизонтали,  $\pm 15^\circ$  по вертикали.

После аугментации набор разделен на обучающую, валидационную и тестовую выборки, которые включают в себя 3150, 150 и 300 изображений соответственно. Для каждого изображения есть файл разметки в формате .txt, который содержит информацию о дефектах на изображении (номер класса и нормированные координаты ограничивающего прямоугольника).

Второй набор данных PCB Defect Dataset содержит 1386 изображений и координаты созданных в графическом редакторе дефектов шести типов, таких как прокол, вырыв, обрыв, короткое замыкание, выступ и островок. Уникальных изображений в данном наборе 693, а остальные получены путем аугментации, заключающейся в повороте этих уникальных изображений на различные углы относительно центра изображения (рис. 2).




Рис. 2. Примеры изображений дефектов из набора данных PCB Defect Dataset

Fig. 2. Defect image samples from the PCB Defect Dataset

Для проведения экспериментов с моделью YOLOv8n OBB набор данных PCB Defect Dataset разбивается на обучающую, валидационную и тестовую выборки в соотношении 8:1:1 соответственно. Перед разбиением он перемешивается, поскольку уникальные и аугментированные изображения находятся в отдельных папках и при этом упорядочены по типу дефекта. Для каждого изображения существует файл разметки в формате .txt, который содержит информацию о дефектах на изображении в формате OBB, описанном выше. Следует отметить, что на одном изображении может присутствовать несколько дефектов одного класса.

Распределение дефектов в наборах данных изображено на рис. 3.




Рис. 3. Распределение дефектов в наборах данных: a) DeepPCB; b) PCB Defect Dataset

Fig. 3. Defect distribution in datasets: a) DeepPCB; b) PCB Defect Dataset

**Метрики оценки.** Для оценки эффективности модели использованы следующие широко применимые к различным моделям обнаружения объектов показатели<sup>8</sup>:

- средняя точность (Average Precision, AP), которая вычисляет площадь под кривой точности (Precision) и полноты (Recall), предоставляя одно значение, которое отражает производительность модели по точности и полноте;

- среднее значение средней точности (mean AP, mAP), расширяющее концепцию AP путем вычисления средних значений AP для нескольких классов объектов, что обеспечивает всестороннюю оценку производительности модели в сценариях обнаружения объектов с несколькими классами;

- точность, которая определяет долю истинно положительных результатов среди всех положительных прогнозов, оценивая способность модели избегать ложноположительных результатов;

- полнота, вычисляющая долю истинно положительных результатов среди всех фактически положительных результатов, измеряя способность модели обнаруживать все экземпляры класса.

Результаты также содержат разбитые по классам показатели эффективности. Такая детальная информация позволяет понять, насколько хорошо модель работает для каждого конкретного класса, особенно в наборах данных с разнообразными категориями объектов. Для каждого класса в наборе данных предоставляются следующие показатели:

- количество изображений в валидационном наборе, содержащих класс объектов;

- количество появлений класса во всех изображениях в валидационном наборе;

- точность обнаруженных объектов, указывающая, сколько было правильных обнаружений;

- полнота, означающая способность модели идентифицировать все экземпляры объектов на изображениях;

- mAP50 – среднее значение средней точности, рассчитанное при пороге IoU со значением 0,50 и учитывающее только «легкие» обнаружения;

- mAP50-95 – среднее значение средней точности, рассчитанное при различных пороговых значениях IoU в диапазоне от 0,50 до 0,95, что дает полное представление о производительности модели при различных уровнях сложности обнаружения.

Помимо числовых показателей, существуют также визуальные результаты, которые могут обеспечить более интуитивное понимание производительности модели<sup>9</sup>:

- кривая «точность-полнота» – интегральная визуализация любой задачи классификации, которая демонстрирует компромисс между точностью и полнотой при различных пороговых значениях, что особенно важно при работе с несбалансированными классами;

- кривая точности, являющаяся графическим представлением значений точности при различных пороговых значениях, которое помогает понять, как меняется точность при изменении порога;

- кривая полноты, иллюстрирующая, как значения полноты изменяются при различных пороговых значениях;

- матрица ошибок, обеспечивающая подробное представление результатов, демонстрируя количество истинно положительных, истинно отрицательных, ложноположительных и ложноотрицательных результатов для каждого класса;

- нормализованная матрица ошибок, являющаяся нормализованной версией матрицы ошибок и представляющая данные в пропорциях, а не в необработанных значениях.

**Постановка экспериментов.** Для первой части экспериментов использовался набор данных DeepPCB. Модель YOLOv8 размером nano, предобученная на наборе данных COCO, была дообучена и протестирована на описанном наборе изображений. Обучение выполнено в среде Google Colab с использованием GPU Tesla T4. Параметры обучения модели YOLOv8n: количество эпох – 50, размер пакета – 16, размер изображения – 640×640, метод оптимизации – AdamW, вес компонента потерь прямоугольника в функции потерь – 7,5.

<sup>8</sup>YOLO Performance Metrics [Electronic resource]. – Mode of access: <https://docs.ultralytics.com/guides/yolo-performance-metrics/>. – Date of access: 11.07.2024.

<sup>9</sup>URL: <https://docs.ultralytics.com/guides/yolo-performance-metrics/>



В первой части экспериментов алгоритм сравнения с эталоном использует бинаризацию методом Оцу и морфологические операции отмыкания и замыкания с круглым структурирующим элементом размерами  $3 \times 3$  и  $5 \times 5$ . Алгоритм сравнения с эталоном использует семантический фильтр, отсеивающий дефекты площадью менее 20 пикселей.

Графики обучения показаны на рис. 4; кривая «точность-полнота», полученная в процессе обучения, – на рис. 5.




Рис. 4. Графики обучения нейронной сети YOLOv8n

Fig. 4. Training graphs for the YOLOv8n neural network




Рис. 5. Кривая «точность-полнота» на этапе обучения

Fig. 5. Precision-recall curve at the training stage

На рис. 6 показаны дефекты (класс и степень уверенности), найденные на изображениях из валидационной выборки.

Результаты работы алгоритма сравнения с эталоном в отдельности и в сочетании с моделью YOLOv8n получены с помощью исходного неаугментированного набора данных. При сочетании алгоритма сравнения с эталоном и модели YOLOv8n к предсказаниям данной модели добавляются предсказания, не выполненные ею, но выполненные алгоритмом сравнения с эталоном.

На рис. 7 представлены дефекты, найденные с помощью гибридного алгоритма, основанного на сравнении с эталоном и использовании нейросетевой модели YOLOv8n. Дефекты обозначены различными цветами: обрыв – розовым, короткое замыкание – зеленым, выступ – красным, вырыв – голубым, прокол – желтым и островок – синим.



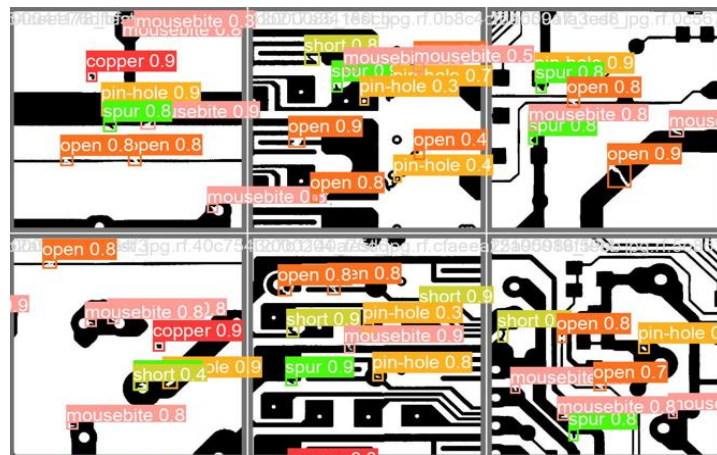


Рис. 6. Дефекты, найденные на изображениях из валидационной выборки  
Fig. 6. Defects found in images from the validation sample




Рис. 7. Дефекты, найденные с помощью гибридного алгоритма  
Fig. 7. Defects found using a hybrid algorithm

Результаты детекции дефектов (число дефектов, метрики оценки производительности модели), полученные на тестовом наборе данных из 300 изображений с помощью обученной модели YOLOv8n, представлены в табл. 1.

Таблица 1  
Результаты детекции дефектов, полученные на тестовом наборе с помощью обученной модели YOLOv8n

Table 1  
Results of defect detection obtained on the test set using the trained YOLOv8n model

Класс Class	Число дефектов Number of defects	Метрика оценки Evaluation metric			
		Precision	Recall	mAP50	mAP50-95
Copper	282	0,983	0,986	0,992	0,858
Mousebite	371	0,933	0,945	0,977	0,698
Open	338	0,906	0,956	0,972	0,654
Pin-hole	309	1	0,964	0,995	0,831
Short	249	0,953	0,928	0,957	0,628
Spur	295	0,975	0,963	0,989	0,705
Все дефекты	1844	0,958	0,957	0,98	0,729

Отчет о классификации дефектов и матрица ошибок, полученные на полном наборе данных DeepPCB с помощью обученной модели YOLOv8n, представлены в табл. 2 и на рис. 8.

Таблица 2

Отчет о классификации, полученный на исходном наборе данных с помощью модели YOLOv8n

Table 2

Classification report obtained on the original dataset using the YOLOv8n model

Класс Class	Число дефектов Number of defects	Метрика оценки Evaluation metric			
		Precision	Recall	F1-score	Accuracy
Pin-hole	1554	0,880 73	0,926 64	0,903 10	—
Mousebite	2081	0,764 01	0,936 57	0,841 54	
Open	2015	0,916 05	0,980 15	0,947 02	
Short	1588	0,933 71	0,948 99	0,941 29	
Spur	1681	0,883 48	0,960 74	0,920 49	
Copper	1506	0,837 85	0,984 73	0,905 37	
Все дефекты	11 768	Macro avg			0,847 13
		0,745 12	0,819 69	0,779 83	
		Weighted avg			
		0,767 68	0,847 13	0,804 60	




Рис. 8. Матрица ошибок для модели YOLOv8n, полученная на наборе данных DeepPCB

Fig. 8. Confusion matrix for the YOLOv8n model obtained on the DeepPCB dataset

Результаты работы алгоритма сравнения с эталоном и гибридного алгоритма на наборе данных DeepPCB представлены в табл. 3 и 4. Матрицы ошибок изображены на рис. 9.

Таблица 3

Отчет о классификации алгоритма сравнения с эталоном на наборе данных DeepPCB

Table 3

Classification report of the reference-based PCB inspection algorithm on the DeepPCB dataset

Класс Class	Число дефектов Number of defects	Метрика оценки Evaluation metric			
		Precision	Recall	F1-score	Accuracy
Pin-hole	1502	0,926 20	0,927 43	0,926 81	—
Mousebite	1971	0,628 37	0,757 48	0,686 91	
Open	1956	0,934 98	0,852 76	0,891 98	
Short	1518	0,982 81	0,866 27	0,920 87	
Spur	1637	0,618 12	0,925 47	0,741 19	
Copper	1480	0,981 21	0,987 84	0,984 51	
Все дефекты	11 712	Macro avg			0,755 29
		0,724 52	0,759 61	0,736 04	
		Weighted avg			
		0,718 44	0,755 29	0,730 79	

Таблица 4  
Отчет о классификации гибридного алгоритма на наборе данных DeepPCB

Table 4  
Classification report of a hybrid algorithm on the DeepPCB dataset

Класс Class	Число дефектов Number of defects	Метрика оценки Evaluation metric			
		Precision	Recall	F1-score	Accuracy
Pin-hole	1662	0,862 88	0,969 31	0,913 01	-
Mousebite	2344	0,620 17	0,931 31	0,744 54	
Open	2189	0,895 35	0,977 16	0,934 47	
Short	1685	0,926 56	0,958 46	0,942 24	
Spur	1964	0,647 79	0,978 62	0,779 56	
Copper	1558	0,834 14	0,994 22	0,907 17	
Все дефекты	14 359	Macro avg			0,767 39
		0,683 84	0,829 87	0,745 86	
		Weighted avg			
		0,625 45	0,767 39	0,685 30	




Рис. 9. Матрицы ошибок, полученные для набора DeepPCB: а) для алгоритма сравнения с эталоном; б) гибридного алгоритма

Fig. 9. Confusion matrices obtained for the DeepPCB set: a) for the reference-based PCB inspection algorithm; b) the hybrid algorithm

Результаты экспериментов показывают, что минимальное количество пропущенных дефектов, а именно 16, достигается при использовании гибридного алгоритма. Нейросетевая модель демонстрирует высокую точность детекции дефектов печатных плат (метрика mAP50 равна 0,98 на тестовом наборе данных). При этом на тестовом наборе для этой модели доля ложноположительных ошибок составляет 11,9 % относительно общего количества дефектов, а доля ложноотрицательных ошибок – 2,8 %. Относительно всех дефектов наихудшее значение доли ложноположительных ошибок соответствует классу «обрыв» и составляет 21,9 %, а наихудшее значение доли ложноотрицательных ошибок соответствует классу «короткое замыкание» и составляет 5,2 %.

Для второй части экспериментов использовался набор изображений дефектов печатных плат PCB Defect Dataset.

Модель YOLOv8 размером папо, предобученная на наборе данных DOTAv1<sup>10</sup>, была дообучена и протестирована на описанном наборе изображений. Обучение выполнено с использованием GPU NVIDIA GeForce RTX 3060. Некоторые параметры обучения модели YOLOv8n OBB: количество эпох – 200, размер пакета – 16, метод оптимизации – Adam, вес компонента потерь прямоугольника в функции потерь – 7,5.

В данной части экспериментов алгоритм сравнения с эталоном использует глобальную бинаризацию – диапазону значения RGB от (0, 20, 0) до (45, 85, 45) соответствует белый цвет, а остальному диапазону – черный. Для совмещения тестируемого изображения и эталона используются масштабно-инвариантная трансформация признаков (Scale Invariant Feature Transform, SIFT)<sup>11</sup>, сопоставление дескрипторов методом Brute-Force<sup>12</sup> и интерполяция методом ближайшего соседа<sup>13</sup>. Морфологические операции отмыкания-замыкания с круглым структурирующим элементом размером 5×5 применяются для сглаживания результатов бинаризации и совмещения.

Графики обучения показаны на рис. 10. Кривая «точность-полнота», полученная в процессе обучения, изображена на рис. 11.




Рис. 10. Графики обучения нейронной сети YOLOv8n OBB

Fig. 10. Training graphs for the YOLOv8n OBB neural network




Рис. 11. Кривая «точность-полнота» на этапе обучения

Fig. 11. Precision-recall curve at the training stage

<sup>10</sup>DOTA. A Large-Scale Benchmark and Challenges for Object Detection in Aerial Images [Electronic resource]. – Mode of access: <https://captain-whu.github.io/DOTA/index.html>. – Date of access: 11.07.2024.

<sup>11</sup>OpenCV: Introduction to SIFT (Scale-Invariant Feature Transform) [Electronic resource]. – Mode of access: [https://docs.opencv.org/4.x/da/df5/tutorial\\_py\\_sift\\_intro.html](https://docs.opencv.org/4.x/da/df5/tutorial_py_sift_intro.html). – Date of access: 11.07.2024.

<sup>12</sup>OpenCV: Feature Matching [Electronic resource]. – Mode of access: [https://docs.opencv.org/4.x/dc/dc3/tutorial\\_py\\_matcher.html](https://docs.opencv.org/4.x/dc/dc3/tutorial_py_matcher.html). – Date of access: 11.07.2024.

<sup>13</sup>OpenCV: Geometric Image Transformations [Electronic resource]. – Mode of access: [https://docs.opencv.org/4.x/da/d54/group\\_\\_imgproc\\_\\_transform.html](https://docs.opencv.org/4.x/da/d54/group__imgproc__transform.html). – Date of access: 11.07.2024.

На рис. 12 показаны дефекты (класс и степень уверенности), найденные на изображениях из валидационной выборки.




Рис. 12. Дефекты, найденные на изображениях из валидационной выборки

Fig. 12. Defects found in images from the validation sample

Результаты детекции дефектов, полученные на тестовом наборе данных из 139 изображений с помощью обученной модели YOLOv8n, представлены в табл. 5.

Таблица 5

Результаты детекции дефектов, полученные на тестовой выборке набора PCB Defect Dataset с помощью модели YOLOv8n

Table 5

Results of defect detection obtained on a test sample of the PCB Defect Dataset using the YOLOv8n model

Класс Class	Число дефектов Number of defects	Метрика оценки Evaluation metric			
		Precision	Recall	mAP50	mAP50-95
Pin-hole	97	1	1	0,995	0,891
Mousebite	93	0,989	1	0,994	0,84
Open	94	1	0,989	0,994	0,848
Short	101	1	0,99	0,995	0,857
Spur	99	0,979	0,949	0,969	0,803
Copper	102	1	1	0,995	0,828
Все дефекты	586	0,995	0,988	0,99	0,844

Отчет о классификации дефектов и матрица ошибок, полученные на тестовой выборке из 139 изображений набора PCB Defect Dataset с помощью обученной модели YOLOv8n, представлены в табл. 6 и на рис. 13, а.

Таблица 6

Отчет о классификации, полученный на тестовой выборке исходного набора данных с помощью модели YOLOv8n

Table 6

Classification report obtained on a test sample of the original dataset using the YOLOv8n model

Класс Class	Число дефектов Number of defects	Метрика оценки Evaluation metric			
		Precision	Recall	F1-score	Accuracy
Copper	102	1	1	1	-
Mousebite	93	0,989 36	1	0,994 65	
Open	94	1	0,989 36	0,994 65	
Pin-hole	97	1	1	1	
Short	101	1	0,9010	0,995 03	
Spur	99	0,979 17	0,949 49	0,964 10	
Все дефекты	586	Macro avg			0,988 05
		0,852 65	0,846 99	0,849 78	
		Weighted avg			
		0,994 79	0,988 05	0,991 37	




Рис. 13. Матрица ошибок, полученная на тестовой выборке набора данных PCB Defect Dataset для обученной модели YOLOv8n OBB (a); матрица ошибок, полученная на полном наборе данных PCB Defect Dataset для алгоритма сравнения с эталоном (b)

Fig. 13. Confusion matrix obtained on a test sample of the PCB Defect Dataset for trained YOLOv8n OBB model (a); confusion matrix obtained on the full PCB Defect Dataset for the reference-based PCB inspection algorithm (b)

Результаты работы алгоритма сравнения с эталоном на полном наборе данных PCB Defect Dataset представлены в табл. 7, а сопутствующая матрица ошибок – на рис. 13, b.

Таблица 7

Результаты работы алгоритма сравнения с эталоном на исходном наборе

Table 7

Results of the reference-based PCB inspection algorithm on the original set

Класс Class	Число дефектов Number of defects	Метрика оценки Evaluation metric			
		Precision	Recall	F1-score	Accuracy
Pin-hole	994	0,995 84	0,963 78	0,979 55	–
Mousebite	993	0,862 24	0,850 96	0,856 56	
Open	977	0,850 19	0,894 58	0,871 82	
Short	1004	0,829 70	0,795 82	0,812 40	
Spur	982	0,798 67	0,731 16	0,763 42	
Copper	1006	0,956 94	0,994 04	0,975 13	
Все дефекты	6055	Macro avg			0,857 80
		0,756 23	0,747 19	0,751 27	
		Weighted avg			
		0,868 16	0,857 80	0,862 48	

По результатам экспериментов нейросетевая модель показывает высокую точность детекции дефектов печатных плат (метрика mAP50 равна 0,99 на тестовом наборе данных). При этом на тестовом наборе для этой модели доля ложноположительных ошибок составляет 0,5 % относительно общего количества дефектов, а доля ложноотрицательных ошибок – 1,2 %. Наихудшие значения данных показателей среди отдельно взятых классов соответствуют классу «выступ». Доля ложноположительных ошибок составляет 2 % относительно всех дефектов данного класса, а доля ложноотрицательных ошибок – 5,1 %.

Как показали проведенные эксперименты, использование нейронных сетей для поиска и классификации дефектов имеет такие преимущества, как низкая чувствительность к качеству изображений, наличие бликов и защитного лака на поверхности печатной платы (кроме случаев непрозрачного или черного лака), присутствие текстовой и графической информации на поверхности печатной платы.

Между тем следует отметить зависимость результатов от полноты и качества обучающей выборки. Все использованные в экспериментах общедоступные наборы данных для обучения нейронных сетей имеют ошибки в разметке данных. Пары изображений (эталонное и анализируемое) в наборе данных Deep PCB не могут быть приемлемо совмещены с помощью аффинных и проекционных преобразований вследствие, предположительно, ошибочных параметров бинаризации и не должны использоваться для контроля, а также принципиально не имеют информации о связях между дорожками за пределами одного кадра. Все печатные платы, изображения которых входят в набор PCB Defects Dataset, покрыты только зеленым защитным лаком. Некоторые изображения имеют белые графические объекты, указывающие на посадочные места электронных компонентов, что значительно усложняет, а в некоторых случаях делает невозможным оптический контроль печатной платы. Дефекты обоих наборов данных выполнены формально с использованием графического редактора. Набор данных Multiple Datasets on PCB Defects<sup>14</sup> содержит только изображения реальных дефектов печатных плат с разными условиями съемки без информации об их классах.

Перечисленные недостатки определяют необходимость гибридного поиска дефектов печатных плат, основанного на использовании алгоритма сравнения с эталоном (вычитании изображений), операций математической морфологии и нейронных сетей.

Гибридный подход заключается в выборе метода поиска дефектов в зависимости от оценки качества анализируемых изображений по следующим критериям:

- отсутствие нелинейных геометрических искажений, обусловленных непостоянством скорости сканирования печатной платы или неоднородностью свойств оптической системы формирования изображения по всему полю кадра;

- наличие бликов и теней из-за использования неудачной системы освещения;

- определение достаточной резкости изображения для обработки;

- определение общего уровня яркости изображения, количества и разнообразия оттенков. Если уровень яркости слишком высокий или, наоборот, низкий, то это приводит к потерям информации на пересвеченных или слишком темных участках изображения при выравнивании яркости.

Для поиска дефектов на изображениях высокого качества при наличии эталона рекомендуется использовать алгоритм сравнения с эталоном, который позволяет классифицировать все найденные дефекты на шесть непересекающихся классов. Для поиска отклонения от минимальной ширины дорожки и минимального расстояния между дорожками будет использоваться операция математической морфологии – дистанционное преобразование, применяемое как к изображению дорожек, так и к фону.

Возможно одновременное применение алгоритма сравнения и нейросетевого подхода с объединением результатов для снижения вероятности пропуска критически важного дефекта и количества ложных дефектов при плохом совмещении эталонного и анализируемого изображений. При отсутствии эталона или низком качестве изображения следует применять предварительно обученные нейронные сети.

При любом выборе метода поиска необходимо использовать его результаты с целью расширения набора данных для обучения и переобучения нейронных сетей, что позволит улучшить качество детекции и классификации дефектов. Особое внимание необходимо уделить вопросу организации грамотного освещения плат и регистрации их изображений. Эти факторы непосредственно влияют на качество поиска дефектов.

<sup>14</sup>Multiple Datasets on PCB Defects [Electronic resource]. – Mode of access://www.kaggle.com/datasets/jiafuwen77/multiple-datasets-on-pcb-defects. – Date of access: 11.07.2024.



**Заключение.** Авторами рассмотрены ключевые факторы, стимулирующие мировой рынок печатных плат, и тенденции в их проектировании и производстве, определяющие актуальность разработки системы поиска дефектов. В работе решена прикладная задача обнаружения и классификации дефектов на изображениях печатных плат на основе алгоритма сравнения с эталоном и нейросетевой архитектуры YOLOv8, проведено обучение моделей на общедоступных наборах изображений дефектов, выполнена оценка качества поиска. Использование архитектуры YOLOv8 показало высокую точность поиска, низкую чувствительность к качеству изображений и присутствию текстовой и графической информации на поверхности печатной платы. Однако недостатки обучающих выборок не позволяют однозначно рекомендовать использование только нейронных сетей для поиска дефектов, поэтому предлагается гибридный подход, который дает возможность улучшать результаты за счет применения разных методов в зависимости от оценки качества анализируемых изображений.

**Вклад авторов.** В. В. Венгеренко осуществил подготовку наборов данных, обучение моделей, оценку точности моделей и алгоритмов. А. В. Инютин выполнил постановку задачи, выбор наборов данных, планирование эксперимента, разработал методику поиска дефектов.

#### Список использованных источников

1. Карпов, С. Прецизионный контроль печатных плат. Что это? / С. Карпов // Технологии в электронной промышленности. – 2008. – № 7. – С. 37–40.
2. A GMR–ECT based embedded solution for applications on PCB inspections / M. Cacciola [et al.] // Sensors and Actuators A: Physical. – 2011. – Vol. 167, iss. 1. – P. 25–33.
3. A survey on industrial vision systems, applications and tools / E. N. Malamas [et al.] // Image and Vision Computing. – 2003. – Vol. 21, iss. 2. – P. 171–188.
4. Interpretation of texture changes during self-annealing of electroplated copper / W. Q. Zhang [et al.] // Microelectronic Engineering. – 2010. – Vol. 87, iss. 12. – P. 2488–2494.
5. Lehmann, D. K. X-ray systems for optimizing PCB inspection: x-ray systems are not all equal, and their differences affect the type of defects that can be detected / D. K. Lehmann // Circuits Assembly. – 2002. – Vol. 13, iss. 2. – P. 35–40.
6. Левданский, А. Оптический и рентгеновский контроль печатных плат при помощи одной системы / А. Левданский // Технологии в электронной промышленности. – 2005. – № 6. – С. 52–54.
7. Ebayyeh, A. A. R. Abu. A review and analysis of automatic optical inspection and quality monitoring methods in electronics industry / A. A. R. Abu Ebayyeh, A. Mousavi // IEEE Access. – 2020. – Vol. 8. – P. 183192–183271.
8. Дудкин, А. А. Техника поиска дефектов и контроля проектных норм на изображении слоев печатных плат / А. А. Дудкин, А. В. Инютин // Искусственный интеллект. – 2006. – № 3. – С. 584–591.
9. Amjoud, A. B. Object detection using deep learning, CNNs and vision transformers: A review / A. B. Amjoud, M. Amrouch // IEEE Access. – 2023. – Vol. 11. – P. 35479–35516.

---

---

#### References

1. Karpov S. *Precision testing of printed circuit boards. What is it?* Tehnologii v jelektronnoj promyshlennosti [Technologies in the Electronics Industry], 2008, no. 7, pp. 37–40 (In Russ.).
2. Cacciola M., Megali G., Pellicano D., Morabito F. C. A GMR–ECT based embedded solution for applications on PCB inspections. *Sensors and Actuators A: Physical*, 2011, vol. 167, iss. 1, pp. 25–33.
3. Malamas E. N., Petrakis E., Zervakis M., Petit L., Legat J. A survey on industrial vision systems, applications and tools. *Image and Vision Computing*, 2003, vol. 21, iss. 2, pp. 171–188.
4. Zhang W. Q., Li A. D., Ma G. B., Yin K. B., Xia Y. D., ..., Yee K. W. Interpretation of texture changes during self-annealing of electroplated copper. *Microelectronic Engineering*, 2010, vol. 87, iss. 12, pp. 2488–2494.
5. Lehmann D. K. X-ray systems for optimizing PCB inspection: x-ray systems are not all equal, and their differences affect the type of defects that can be detected. *Circuits Assembly*, 2002, vol. 13, iss. 2, pp. 35–40.
6. Levdanskiy A. *Optical and X-ray inspection of printed circuit boards using one system.* Tehnologii v jelektronnoj promyshlennosti [Technologies in the Electronics Industry], 2005, no. 6, pp. 52–54 (In Russ.).

7. Ebayyeh A. A. R. Abu, Mousavi A. A review and analysis of automatic optical inspection and quality monitoring methods in electronics industry. *IEEE Access*, 2020, vol. 8, pp. 183192–183271.

8. Dudkin A. A., Inyutin A. V. *Techniques for detecting defects and checking design standards on the image of printed circuit board layers*. *Iskusstvennyj intellekt [Artificial Intelligence]*, 2006, no. 3, pp. 584–591 (In Russ.).

9. Amjoud A. B., Amrouch M. Object detection using deep learning, CNNs and vision transformers: A review. *IEEE Access*, 2023, vol. 11, pp. 35479–35516.

### Информация об авторах

*Венгеренко Вадим Владимирович*, магистр, младший научный сотрудник лаборатории идентификации систем, Объединенный институт проблем информатики Национальной академии наук Беларуси.  
E-mail: [vengerenko@lsi.bas-net.by](mailto:vengerenko@lsi.bas-net.by)

*Инютин Александр Владимирович*, заведующий лабораторией идентификации систем, Объединенный институт проблем информатики Национальной академии наук Беларуси.  
E-mail: [avin@newman.bas-net.by](mailto:avin@newman.bas-net.by)

### Information about the authors

*Vadim V. Vengerenko*, Master, Junior Researcher of the Laboratory of System Identification, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus.  
E-mail: [vengerenko@lsi.bas-net.by](mailto:vengerenko@lsi.bas-net.by)

*Alexander V. Inyutin*, Head of the Laboratory of System Identification, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus.  
E-mail: [avin@newman.bas-net.by](mailto:avin@newman.bas-net.by)