

УДК 621.3:004.032.26

Нейросетевая классификация дефектов печатных плат

Романов Кирилл Ильич — студент кафедры «Интеллектуальные системы в управлении и автоматизации». Научные интересы: автоматизация технологических процессов. E-mail: kiromanov@ieeras.ru

Бабаев Азизбек Адахамжанович — студент кафедры «Интеллектуальные системы в управлении и автоматизации». Научные интересы: автоматизация технологических процессов. E-mail: azizkagif@yandex.ru

Антонычева Ольга Леонидовна — старший преподаватель кафедры «Интеллектуальные системы в управлении и автоматизации». Научные интересы: методы машинного обучения. E-mail: o.l.antonycheva@mtuci.ru

Московский технический университет связи и информатики, Россия, 111024, Москва, ул. Авиамоторная, д. 8А

Для цитирования: Романов К. И., Бабаев А. А., Антонычева О. Л. Нейросетевая классификация дефектов печатных плат // Интеллектуальные технологии на транспорте. 2025. № 2 (42). С. 29–41. DOI: 10.20295/2413-2527-2025-242-29-41

Аннотация. Рассматривается разработка модели на основе нейросети YOLOv8x для автоматизированного выявления дефектов на печатных платах. **Цель:** обучение нейросети, способной эффективно обнаруживать и классифицировать различные виды дефектов на печатных платах. **Методы:** использовался метод глубокого обучения, основанный на архитектуре YOLOv8x, предназначенной для задач детектирования объектов. Для оценки эффективности модели проводился анализ метрик точности и потерь. **Результаты:** показывают, что обученная модель демонстрирует высокую точность в классификации дефектов, таких как незапаянное посадочное место (*missing_hole*), короткое замыкание (*short*) и ложная печатная дорожка (*spurious_copper*), достигая точности 1,0. Классы «разомкнутая печатная дорожка» (*open_circuit*) и «выступ меди» (*spur*) также показывают удовлетворительные результаты, однако класс «нарушение целостности печатной дорожки» (*mouse_bite*) требует дальнейшего улучшения. **Практическая значимость:** заключается в возможности применения разработанной модели для автоматизации процессов контроля качества печатных плат, что может значительно повысить надежность электронных изделий и снизить вероятность отказов в критически важных системах.

Ключевые слова: печатная плата, дефекты, нейросетевая классификация, нейросетевая модель YOLOv8x

1.2.1 — искусственный интеллект и машинное обучение (технические науки)

Введение

Современные электронные изделия создаются на основе печатного монтажа, представляющего собой многослойную структуру из диэлектрика и проводящего слоя. Надежность таких изделий особенно критична в космической, авиационной и военной отраслях, где эксплуатация проходит в

жестких условиях. До 40 % отказов электронных средств (ЭС) связано с дефектами печатных плат (ПП), возникающими из-за нарушений технологии производства [1].

Для обнаружения дефектов ПП используют информационно-измерительные системы (ИИС), кото-

рые обеспечивают контроль на всех этапах производства. Среди методов контроля широко применяются оптический, рентгеновский, электрический и тепловой. Наиболее экономичным и быстрым является оптический метод, который позволяет выявлять дефекты как ПП, так и печатных узлов. Однако ручной контроль имеет высокую вероятность пропуска дефектов, что требует автоматизации анализа [2].

Внедрение нейросетевых технологий в контроль качества ПП открывает новые возможности для повышения точности диагностики. Нейросети, обученные на данных о дефектах, способны автоматически выявлять и классифицировать недостатки, сокращая время и снижая затраты. Обработка данных в реальном времени позволяет предотвратить попадание бракованных плат в продукцию, что снижает издержки на доработку и замену [3].

Нейросети, принцип работы, применение

Нейронная сеть — это программа, имитирующая работу естественной нейронной сети мозга для решения задач и машинного обучения.

Знания в нейронной сети распределены между ее элементами (искусственными нейронами) через связи с адаптивными весами. Сеть обучается, регулируя веса соединений между нейронами, сгруппированными в слои. Входной слой получает информацию, выходной передает ответ, а скрытые слои обрабатывают данные. Выход зависит от весов связей: если сумма взвешенных входных сигналов превышает порог, нейрон отправляет сигнал дальше [4].

Нейросети находят широкое применение в различных областях благодаря своей способности обрабатывать большие объемы данных и выявлять сложные закономерности [5].

В производстве возобновляемой энергии, включая оценку, обслуживание и управление, применение искусственного интеллекта и нейронных сетей позволит улучшить все аспекты. Цифровизация сектора создаст гибкие и устойчивые энергетические системы, что сделает возобновляемую энергию основным источником электроэнергии [6].

В компьютерном зрении они активно используются для распознавания изображений и видео [7, 8], что находит применение в системах безопасно-

сти [9], автономных транспортных средствах [10] и медицинской диагностике [11].

В области обработки естественного языка нейросети применяются для перевода текстов [12], создания чат-ботов [13] и извлечения ключевых слов [14].

Исследования показывают [15], что искусственный интеллект активно используется в финансах, особенно в области финансового прогнозирования, защиты и анализа. Основной технологией является контролируемое обучение, а глубокое обучение стало популярным в последние годы.

В здравоохранении нейросети используются для диагностики заболеваний, прогнозирования эпидемий и персонализированного лечения, анализируя генетические данные и медицинские записи для разработки индивидуальных планов лечения [16–20].

В производственных процессах нейросети активно применяются для улучшения аналитических и предсказательных возможностей систем поддержки принятия решений, что позволяет справляться с растущей сложностью и неопределенностью, обеспечивая более эффективное принятие решений и оптимизацию затрат [21].

С учетом технологического прогресса последних десятилетий, технологии и автоматизация стали важными факторами роста, а применение роботизированной автоматизации процессов и алгоритмов искусственного интеллекта значительно улучшает точность и эффективность технологических процессов [22].

Автоматизация с использованием нейросетей уменьшает влияние человеческого фактора, обеспечивая стабильное качество продукции и улучшая производственные процессы [23]. Интеграция нейросетей в контроль дефектов ПП является перспективным направлением для повышения надежности электронных изделий, сокращения затрат и ускорения выхода продукции на рынок.

Используемый датасет

Набор данных печатных плат [24] состоит первоначально из 1386 изображений с 6 видами дефектов: незапаянное посадочное место (*missing hole*),




Рис. 1. Пример фотографии из набора данных




Рис. 2. Пример фотографии из набора данных с использованием информационных рамок

разомкнутая печатная дорожка (*open_circuit*), короткое замыкание (*short*), выступ меди (*spur*), ложная печатная дорожка (*spurious_copper*), нарушение целостности печатной дорожки (*mouse_bite*).

Пример фотографии из набора данных приведен на рис. 1.

Для удобства восприятия информации о печатных платах на фотографиях размечены соответствующие области. С использованием функции `cv2.rectangle` отображаются информационные рамки по заранее известным координатам дефектов (рис. 2).

Общее количество фотографий составило 693 (табл. 1). Это обусловлено тем, что половина датасета представляет собой дубликаты, которые были повернуты в диапазоне от -10 до 10° . В исследовании повернутые дубликаты не учитывались.

В работе [25] авторы упоминают о способах повышения качества распознавания. Основное

улучшение качества распознавания изображений обеспечила аугментация, которая увеличила объем обучающей выборки с помощью искажений (масштабирование, сдвиг, отражение, поворот). Кадрирование изображений для обучающей, валидационной и тестовой выборок также повысило точность, исключив избыточную информацию.

Однако цель данной работы состоит в обучении нейросети и возможности распознавания с ее помощью дефектов на печатных платах. Повышение качества распознавания требует дополнительных исследований.

В табл. 1 приведено количество фотографий по каждому типу дефектов, а также выведена информация по количеству дефектов на всех фотографиях, рассчитано среднее количество дефектов на фотографии. Получается, что среднее количество дефектов на фотографии для всего датасета равно 4,25, а медианное значение (среднее из

Таблица 1

Содержание датасета

Название класса	Количество дефектов на всех фотографиях	Количество фотографий	Среднее количество дефектов на фотографии
missing_hole	497	115	4,32
mouse_bite	492	115	4,28
open_circuit	482	116	4,15
short	491	116	4,23
spur	488	115	4,24
spurious_copper	503	116	4,34




Рис. 3. Файл 04_short_06.jpg

центральных, упорядоченных значений) — 4,26. Близкие значения среднего значения и медианы говорят о равномерном распределении данных без сильных колебаний.

Равномерность данных создает благоприятные условия для обучения модели. Каждый тип дефекта представлен примерно в равных количествах, что позволяет обучаться без предвзятости к каким-либо конкретным классам: модель будет лучше распознавать все типы дефектов, а не только те, которые встречаются чаще.

Равномерное распределение данных также снижает риск переобучения, поскольку модель будет вынуждена учитывать все классы на протяжении всего процесса обучения. Это, в свою очередь, помогает повысить устойчивость к выбо-

сам и аномалиям в данных, что делает обучение более стабильным и предсказуемым. Кроме того, модель, обученная на равномерных данных, будет обладать лучшей обобщающей способностью. Она сможет эффективно применять свои знания к новым, ранее невидимым данным, что является ключевым аспектом успешного применения в реальных задачах. Таким образом, равномерное распределение данных по типам дефектов способствует созданию более эффективной и точной модели распознавания.

Мультискейл-обучение особенно полезно в ситуациях, когда объекты имеют разные размеры, оно подразумевает использование нескольких масштабов входных изображений. Во время обучения изображения случайным образом изменяются по размеру, и модель обучается на пакетах изображений разных масштабов. Модель YOLO обновляется с учетом градиентов, вычисленных на основе функции потерь для каждого масштаба изображения, что позволяет ей эффективно обнаруживать объекты различных размеров [26].

В нашем исследовании изображения приводились к единому размеру: 640 на 640 пикселей (рис. 3). Это связано с необходимостью обеспечить высокую скорость обработки и эффективность алгоритма детекции объектов. Меньшие изображения требуют меньше вычислительных ресурсов, что делает модель способной обрабатывать больше кадров в секунду. Выбранный размер является компромиссом, который позволяет сохранить достаточное количество деталей для точной детекции объектов, а также эффективно справляться с задачей выявления объектов разных размеров.

Таблица 2

Аннотация дефектов на примере файла 04_short_06.jpg

Файл	Ширина	Высота	Класс	x_{min}	y_{min}	x_{max}	y_{max}
04_short_06.jpg	640	640	short	249	142	266	162
04_short_06.jpg	640	640	short	261	61	278	83
04_short_06.jpg	640	640	short	174	226	194	248

В табл. 2 представлена аннотация дефектов на примере файла 04_short_06.jpg.

В данном файле видно три дефекта, каждый из которых описан с указанием координат и класса. После применения функции `resize_annotations` произошли изменения в аннотациях изображения.

DataFrame аннотаций (на примере файла 04_short_06.jpg) содержит следующие характеристики: ширина и высота изображения (640 пикселей), класс дефекта (short). Координаты для каждого дефекта указаны в формате `xmin`, `ymin`, `xmax`, `ymax`, они необходимы для обучения нейросети, а также корректной работы функции `cv2.rectangle`.

Обучение нейросети YOLOv8x

Архитектура YOLO (You Only Look Once) [27] является одной из ключевых разработок в области детекции объектов в реальном времени. Базовая модель YOLO способна обрабатывать изображения в реальном времени со скоростью 45 кадров в секунду, а более компактная версия, Fast YOLO, достигает невероятных 155 кадров в секунду. При этом она демонстрирует в два раза более высокие значения mAP по сравнению с другими системами детекции в реальном времени [28]. Это делает YOLO идеальным выбором для поиска дефектов на печатных платах.

В рамках исследования проведены эксперименты с использованием бесплатной интерактивной облачной среды для работы с кодом на языке Python от Google в браузере Google Colab [29]. В табл. 3 представлены основные параметры обучения нейросети YOLOv8x.

Результаты обучения нейросети YOLOv8x

В процессе обучения модели YOLOv8x мы оценивали ее производительность с помощью не-

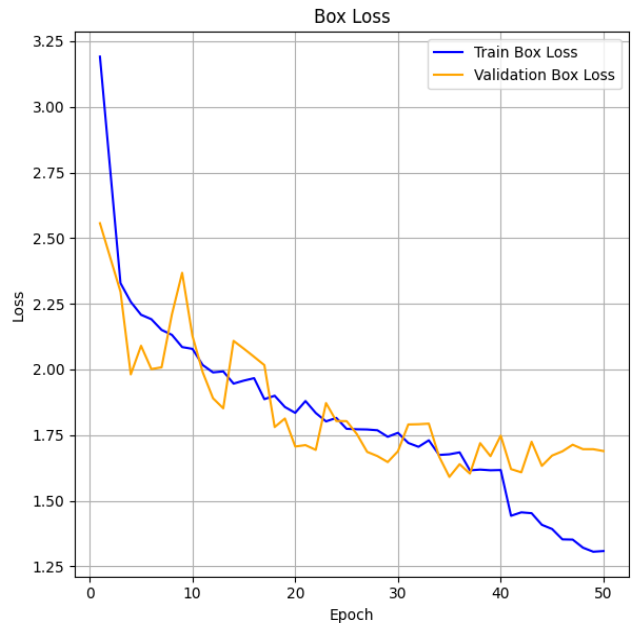


Рис. 4. Метрика обученной нейросети: Box Loss

Таблица 3

Параметры нейросети YOLOv8x

Параметр	Значение
Размер батча	16
Количество эпох	50
Смешивание (mixup)	0,3
Начальная скорость обучения (lr0)	0,001
Конечная скорость обучения (lr1)	0,0001

скольких ключевых метрик: Box Loss, Class Loss и Distribution Focal Loss (рис. 4–6) для обучающей (train) и валидационной (validate) выборки. Эти метрики помогают анализировать качество предсказаний модели в контексте выявления и классификации дефектов.

Box Loss снижается на протяжении всех эпох (рис. 4). Это указывает на то, что модель успешно оптимизировала предсказания ограничивающих рамок для дефектов, улучшая точность локализа-

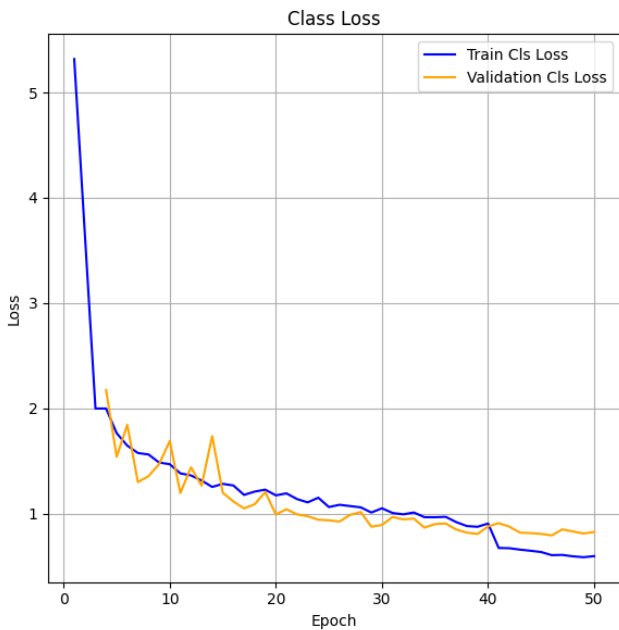


Рис. 5. Метрика обученной нейросети: Class Loss

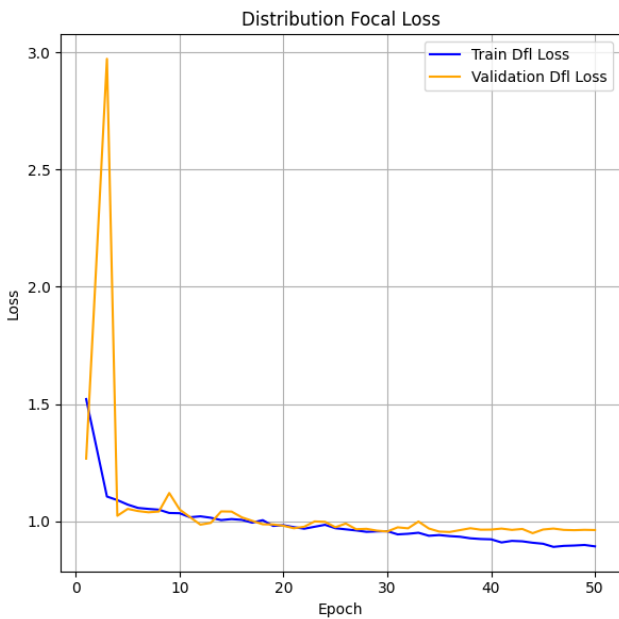


Рис. 6. Метрика обученной нейросети: Distribution Focal Loss

ции (определения местоположения) дефектов на печатных платах. Ситуация, наступившая после 40 эпохи обучения, когда значение Vox Loss на обучающей выборке значительно снижается, в то время как на валидационной выборке оно остается на одном уровне и даже имеет тенденцию к незначительному увеличению, может указывать на переобучение модели.

Class Loss показывает стабильное снижение (рис. 5), что говорит о том, что модель улучшает

свои способности к классификации различных типов дефектов. После 40 эпохи Class Loss на обучающей выборке снижается, в то время как на валидационной выборке остается на одном уровне или даже демонстрирует локальные максимумы, это может указывать на переобучение модели.

Distribution Focal Loss демонстрирует тенденцию к снижению на протяжении всех эпох как для обучающей, так и для валидационной выборки (рис. 6). При этом после 35 эпохи обучения данная метрика практически не меняется для валидационной выборки. Это указывает на то, что модель начинает запоминать данные из обучающей выборки, не извлекая общие закономерности, которые могли бы помочь ей на новых данных, и может быть признаком переобучения.

Модель достигла плато в процессе обучения, и текущие параметры могут быть неоптимальными для дальнейшего прогресса. В таких случаях стоит рассмотреть возможность изменения архитектуры модели, использования методов аугментации, изменения скорости обучения или варьирование других гиперпараметров.

Нормализованная матрица классов (рис. 7) позволяет оценить качество работы модели классификации. Она показывает, насколько точно модель распознает различные классы и как часто она путает их друг с другом.

Классы `missing_hole`, `short` и `spurious_copper` имеют полную точность (1,0), в то время как `open_circuit` и `spur` показывают хорошие результаты (0,82 и 0,81). Класс `mouse_bit` имеет низкую точность (0,67), что указывает на трудности в классификации, вероятно, из-за недостатка разнообразия данных.

Метрика F1-Score (рис. 8) — это среднее гармоническое значение точности [30]. При пороге модель показывает наилучшие результаты в сочетании точности и полноты.

Метрика F1-Score имеет максимальные значения для всех классов на плато с 0,1 до 0,7 по оси X (уверенности), это означает, что в этом диапазоне значений уверенности модель показывает стабильные и хорошие результаты по сочетанию точности и полноты.




Рис. 7. Нормализованная матрица




Рис. 8. Метрика F1-Score

Пример распознавания обученной модели

На рис. 9 и 10 представлены результаты работы обученной модели, предназначенной для обнаружения дефектов.

Рядом с типом дефекта указано значение вероятности в круглых скобках. Это значение отражает вероятность, с которой обученная модель предполагает наличие данного дефекта.




Рис. 9. Пример работы обученной модели с дефектами типа «разомкнутая цепь» (open circuit)

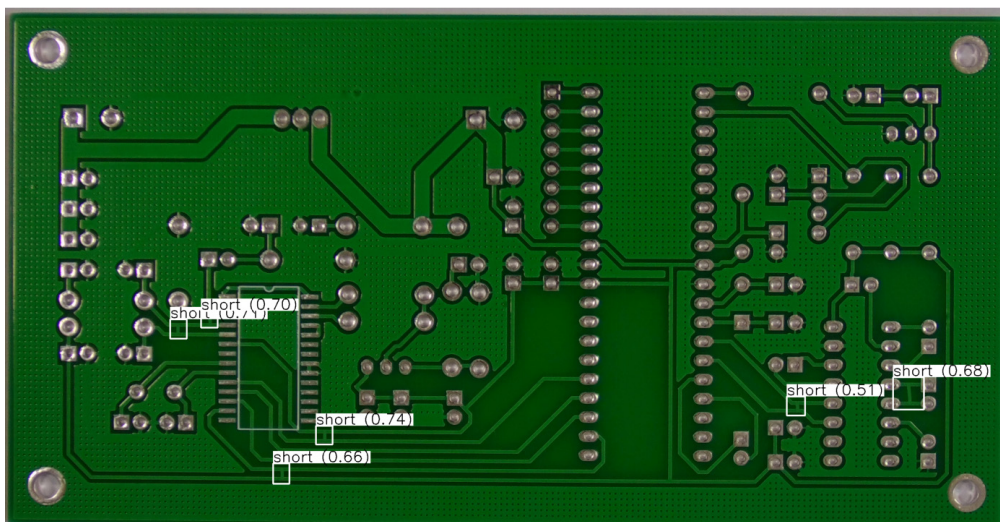


Рис. 10. Пример работы обученной модели с дефектами типа «короткое замыкание» (short)

Заключение

Современные электронные изделия, основанные на печатных платах, требуют высокого уровня надежности, особенно в критически важных отраслях, таких как космическая, авиационная и военная промышленность. Дефекты печатных плат, возникающие из-за нарушений технологических процессов, являются одной из основных причин отказов электронных средств.

Обучение YOLOv8x на специализированном датасете с шестью видами дефектов позволило получить модель, которая демонстрирует полную уверенность в классах `missing_hole`, `short` и

`spurious_copper`, достигая точности 1,0. Классы `open_circuit` и `spur` также показывают хорошие результаты с точностью 0,82 и 0,81 соответственно. Однако класс `mouse_bit` имеет более низкую точность, составившую 0,67.

В процессе обучения модели наблюдается снижение `Box Loss` и `Class Loss`, что свидетельствует о прогрессе в локализации и классификации дефектов. Однако после 40 эпохи обучения возникает проблема переобучения, так как значения метрик на валидационной выборке остаются стабильными или даже увеличиваются, что указывает на недостаток обобщающих способ-

ностей модели. В связи с этим для улучшения результатов следует рассмотреть возможность изменения архитектуры модели и оптимизации гиперпараметров. Оптимизация параметров обучения нейросети не является целью

данной работы и требует дополнительных исследований.

Проведенные эксперименты продемонстрировали, что обученная нейросеть YOLOv8x способна эффективно выявлять дефекты печатных плат.

СПИСОК ИСТОЧНИКОВ

1. Данилова Е. А. Классификация дефектов печатных плат // Труды Международного симпозиума «Надежность и качество» (Пенза, Россия, 27 мая — 03 июня 2013 г.): в 2 т. Пенза: Пензенский гос. ун-т, 2013. Т. 1. С. 325–328.
2. Данилова Е. А., Кочегаров И. И., Трусов В. А. Модели технологических дефектов проводящего рисунка печатных плат // Надежность и качество сложных систем. 2017. № 2 (18). С. 68–76. DOI: 10.21685/2307-4205-2017-2-10.
3. Складнова М. С. Методы контроля печатных плат // Colloquium-journal. 2019. № 25-2 (49). С. 95–97. DOI: 10.24411/2520-6990-2019-10882.
4. Ксенофонтов В. В. Нейронные сети // Проблемы науки. 2020. № 11 (59). С. 28–29.
5. Smith R. G., Eckroth J. Building AI Applications: Yesterday, Today, and Tomorrow // AI Magazine. 2017. Vol. 38, No. 1. Pp. 6–22. DOI: 10.1609/aimag.v38i1.2709.
6. Yağcı B. E., Demirsoy G., Akpolat A. N. General Overview of Artificial Neural Network Applications in Renewable Energy Systems // Turkish Journal of Electromechanics and Energy. 2024. Vol. 9, No. 3. Pp. 95–107.
7. Алексеева Н. С. Распознавание лиц по фотографии с помощью нейронных сетей // Международный студенческий научный вестник. 2021. № 1. 5 с. URL: <http://eduherald.ru/ru/article/view?id=20406> (дата обращения: 17.01.2025).
8. Шарипова Д. Д. Нейронная сеть ImageAI: распознавание объектов // Информационные технологии. Проблемы и решения. 2020. № 2 (11). С. 140–144.
9. Бондаренко В. И., Нестругина Е. С. Система распознавания лиц преступников с помощью камер видеонаблюдения // Донецкие чтения 2022: образование, наука, инновации, культура и вызовы современности: материалы VII Международной научной конференции, посвящённой 85-летию Донецкого национального университета (Донецк, 27–28 октября 2022 г.). Т. 2. Физические, технические и компьютерные науки / под общ. ред. С. В. Беспаловой. Донецк: Донецкий нац. ун-т, 2022. С. 236–237.
10. Боликов С. С. Машинное зрение и нейронные сети / С. С. Боликов; науч. рук. Е. И. Шишков // Конкурентоспособность территорий: материалы XX Всероссийского экономического форума молодых ученых и студентов (Екатеринбург, Россия, 27–28 апреля 2017 г.): в 8 ч. Ч. 8. Екатеринбург: Уральский гос. экон. ун-т, 2017. С. 21–22.
11. Artificial Intelligence (AI) Applications for COVID-19 Pandemic / R. Vaishya, M. Javaid, I. H. Khan, A. Haleem // Diabetes and Metabolic Syndrome: Clinical Research and Reviews. 2020. Vol. 14, Iss. 4. Pp. 337–339. DOI: 10.1016/j.dsx.2020.04.012.
12. The Impact of Artificial Intelligence on Language Translation: A Review / Y. A. Mohamed, A. Khanan, M. Bashir [et al.] // IEEE Access. 2024. Vol. 12. Pp. 25553–25579. DOI: 10.1109/ACCESS.2024.3366802.
13. Муратова У. Д. Изучение нейронных сетей для чат-ботов / У. Д. Муратова; науч. рук. П. В. Балакшин // Сборник трудов IX Конгресса молодых ученых (Санкт-Петербург, Россия, 15–18 апреля 2020 г.). Т. 1. СПб.: Университет ИТМО, 2021. С. 92–95.
14. Алгоритм оптимизации извлечения ключевых слов на основе применения лингвистического парсера / Д. Ю. Кравченко, Ю. А. Кравченко, А. Мансур [и др.] // Информатика и автоматизация. 2024. Т. 23, № 2. С. 467–494. DOI: 10.15622/ia.23.2.6.
15. Artificial Intelligence Applications in Finance: A Survey / X. Li, A. Sigov, L. Ratkin [et al.] // Journal of Management Analytics. 2023. Vol. 10, Iss. 4. Pp. 676–692. DOI: 10.1080/23270012.2023.2244503.

16. Joshi N., Dave T. Improved Accuracy for Heart Disease Diagnosis Using Machine Learning Techniques // Journal of Informatics and Web Engineering. 2025. Vol. 4, No. 1. Pp. 42–52. DOI: 10.33093/jiwe.2025.4.1.4.
17. Datilo P. M., Ismail Z., Dare J. A Review of Epidemic Forecasting Using Artificial Neural Networks // Epidemiology and Health System Journal. 2019. Vol. 6, Iss. 3. Pp. 132–143. DOI: 10.15171/ijer.2019.24.
18. Atan O., Jordon J., van der Schaar M. Deep-Treat: Learning Optimal Personalized Treatments from Observational Data Using Neural Networks // Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence (New Orleans, LA, USA, 02–07 February 2018). Palo Alto (CA): AAAI Press, 2018. Pp. 2071–2078. DOI: 10.1609/aaai.v32i1.11841.
19. Deep Neural Network Provides Personalized Treatment Recommendations for *de novo* Metastatic Breast Cancer Patients / C. Li, Y. Wang, H. Bai [et al.] // Journal of Cancer. 2024. Vol. 15, Iss. 20. Pp. 6668–6685. DOI: 10.7150/jca.101293.
20. Review of Application YOLOv8 in Medical Imaging / A. Widayani, A. M. Putra, A. R. Maghrieibi [et al.] // Indonesian Applied Physics Letters. 2024. Vol. 5, No. 1. Pp. 23–33. DOI: 10.20473/iapl.v5i1.57001.
21. Mumali F. Artificial Neural Network-Based Decision Support Systems in Manufacturing Processes: A Systematic Literature Review // Computers and Industrial Engineering. 2022. Vol. 165. Art. No. 107964. 20 p. DOI: 10.1016/j.cie.2022.107964.
22. Robotic Process Automation and Artificial Intelligence in Industry 4.0 — A Literature Review / J. Ribeiro, R. Lima, T. Eckhardt, S. Paiva // Procedia Computer Science. 2021. Vol. 181. Pp. 51–58. DOI: 10.1016/j.procs.2021.01.104.
23. Еделев Д. А., Благовещенская М. М., Благовещенский И. Г. Использование нейронных сетей как фактора повышения качества и безопасности производства пищевых продуктов при решении задач автоматизации // Автоматизация технологических и бизнес-процессов. 2015. Т. 7, № 1 (21). С. 7–10. DOI: 10.15673/2312-3125.21/2015.42856.
24. Akhatova A. PCB Defects // Kaggle. URL: <http://www.kaggle.com/datasets/akhatova/pcb-defects> (дата обращения: 17.01.2025).
25. Черемисинова О. Н., Ростовцев В. С. Повышение качества распознавания изображений подбором параметров сверточной нейронной сети // Интеграция науки в современном мире: сборник научных работ 52-й Международной научной конференции Евразийского Научного Объединения (Москва, Россия, июнь 2019 г.). М.: Евразийское Научное Объединение, 2019. С. 114–118.
26. Statistical Analysis of Design Aspects of Various YOLO-Based Deep Learning Models for Object Detection / U. Sirisha, S. P. Praveen, P. N. Srinivasu [et al.] // International Journal of Computational Intelligence Systems. 2023. Vol. 16. Art. No. 126. 29 p. DOI: 10.1007/s44196-023-00302-w.
27. Ultralytics YOLO. URL: <http://www.ultralytics.com/ru/yolo> (дата обращения: 17.01.2025).
28. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), (Las Vegas, NV, USA, 27–30 June 2016). Institute of Electrical and Electronics Engineers, 2016. Pp. 779–788. DOI: 10.1109/CVPR.2016.91.
29. Google Colaboratory. URL: <http://colab.google> (дата обращения: 17.01.2025).
30. F1-Score // Ultralytics. URL: <http://www.ultralytics.com/ru/glossary/f1-score> (дата обращения: 17.01.2025).

Дата поступления: 26.03.2025

Решение о публикации: 15.05.2025

Neural Network Classification of Printed Circuit Board Defects

- Kirill I. Romanov** — Student, Department of Intelligent Systems in Management and Automation. Research interests: automation of technological processes. E-mail: kiromanov@ieeras.ru
- Azizbek A. Babaev** — Student, Department of Intelligent Systems in Management and Automation. Research interests: automation of technological processes. E-mail: azizkagif@yandex.ru
- Olga L. Antonycheva** — Senior Lecturer, Department of Intelligent Systems in Management and Automation. Research interests: machine learning. E-mail: o.l.antonycheva@mtuci.ru

Moscow Technical University of Communications and Informatics, 8A, Aviamotornaya str., Moscow, 111024, Russia

For citation: Romanov K. I., Babaev A. A., Antonycheva O. L. Neural Network Classification of Printed Circuit Board Defects. *Intellectual Technologies on Transport*, 2025, No. 2 (42), Pp. 29–41. DOI: 10.20295/2413-2527-2025-242-29-41. (In Russian)

Abstract. *This study focuses on the development of a model based on the YOLOv8x neural network for the automated detection of defects in printed circuit boards (PCBs). **Purpose:** to train a neural network capable of effectively detecting and classifying various types of PCB defects. **Methods:** a deep learning method based on the YOLOv8x architecture, designed for object detection tasks. An accuracy and loss metrics analysis was conducted to assess the model's effectiveness. **Results:** the trained model demonstrates high accuracy in classifying defects such as missing holes, shorts, and spurious copper, achieving an accuracy of 1.0. The “open circuits” and “copper spurs” classes also yield satisfactory results. However, the “mouse bites” class requires further improvement. **Practical significance:** the potential application of the developed model for automating quality control processes in PCBs could significantly enhance the reliability of electronic devices and reduce the potential failures in critical systems.*

Keywords: printed circuit board, defects, neural network classification, YOLOv8x neural network model

REFERENCES

1. Danilova E. A. Klassifikatsiya defektov pechatnykh plat [Classification of printed circuit board defects], *Trudy Mezhdunarodnogo simpoziuma “Nadezhnost i kachestvo” [Proceedings of the International Symposium “Reliability and Quality”]*, Penza, Russia, May 27 — June 03, 2013. Vol. 1. Penza, Penza State University, 2013, Pp. 325–328. (In Russian)
2. Danilova E. A., Kochegarov I. I., Trusov V. A. Modeli tekhnologicheskikh defektov provodyashchego risunka pechatnykh plat [Models of Technological Defects of Conductive Patterns of Printed Circuit Boards], *Nadezhnost i kachestvo slozhnykh sistem [Reliability and Quality of Complex Systems]*, 2017, No. 2 (18), Pp. 68–76. DOI: 10.21685/2307-4205-2017-2-10. (In Russian)
3. Skladnova M. S. Metody kontrolya pechatnykh plat [PCB Control Methods], *Colloquium-journal*, 2019, No. 25-2 (49), Pp. 95–97. DOI: 10.24411/2520-6990-2019-10882. (In Russian)
4. Ksenofontov V. V. Neyronnye seti [Neural networks], *Problemy nauki*, 2020, No. 11 (59), Pp. 28–29. (In Russian)
5. Smith R. G., Eckroth J. Building AI Applications: Yesterday, Today, and Tomorrow, *AI Magazine*, 2017, Vol. 38, No. 1, Pp. 6–22. DOI: 10.1609/aimag.v38i1.2709.
6. Yağcı B. E., Demirsoy G., Akpolat A. N. General Overview of Artificial Neural Network Applications in Renewable Energy Systems, *Turkish Journal of Electromechanics and Energy*, 2024, Vol. 9, No. 3, Pp. 95–107.
7. Alekseeva N. S. Raspoznavanie lits po fotografii s pomoshchyu neyronnykh setey [Face Recognition from a Photo Using Neural Networks], *Mezhdunarodnyy studencheskiy nauchnyy vestnik*, 2021, No. 1, 5 p. Available at: <http://eduherald.ru/ru/article/view?id=20406> (accessed: January 17, 2025). (In Russian)

8. Sharipova D. D. Neyronnaya set ImageAI: raspoznavanie obektov [ImageAI Neural Network: Object Recognition], *Informatsionnye tekhnologii. Problemy i resheniya [Information Technology]*, 2020, No. 2 (11), Pp. 140–144. (In Russian)
9. Bondarenko V. I., Nestrugina E. S. Sistema raspoznavaniya lits prestupnikov s pomoshchyu kamer videonablyudeniya [Facial recognition system for criminals using CCTV cameras], *Donetskie chteniya 2022: obrazovanie, nauka, innovatsii, kultura i vyzovy sovremennosti: materialy VII Mezhdunarodnoy nauchnoy konferentsii [Donetsk Readings 2022: Education, Science, Innovation, Culture and Challenges of Our Time: Proceedings of the VII International Scientific Conference]*, Donetsk, October 27–28, 2022. Vol. 2. Donetsk: Donetsk National University, 2022, Pp. 236–237. (In Russian)
10. Bolikov S. S. Mashinnoe zrenie i neyronnye seti [Machine vision and neural networks], *Konkurentosposobnost territoriy: materialy XX Vserossiyskogo ekonomicheskogo foruma molodykh uchenykh i studentov [Competitiveness of territories: Proceedings of the XX All-Russian Economic Forum of Young Scientists and Students]*, Yekaterinburg, Russia, April 27–28, 2017. Part 8. Yekaterinburg, Ural State University of Economics, 2017, Pp. 21–22. (In Russian)
11. Vaishya R., Javaid M., Khan I. H., Haleem A. Artificial Intelligence (AI) Applications for COVID-19 Pandemic, *Diabetes and Metabolic Syndrome: Clinical Research and Reviews*, 2020, Vol. 14, Iss. 4, Pp. 337–339. DOI: 10.1016/j.dsx.2020.04.012.
12. Mohamed Y. A., Khanan A., Bashir M., et al. The Impact of Artificial Intelligence on Language Translation: A Review, *IEEE Access*, 2024, Vol. 12, Pp. 25553–25579. DOI: 10.1109/ACCESS.2024.3366802.
13. Muratova U. D. Izuchenie neyronnykh setey dlya chat-botov [Study of Neural Networks for Chatbots], *Sbornik trudov IX Kongressa molodykh uchenykh [Proceedings of the IX Congress of Young Scientists]*. Saint Petersburg, Russia, April 15–18, 2020. Vol. 1. Saint Petersburg, ITMO University, 2021, Pp. 92–95. (In Russian)
14. Kravchenko D. Yu., Kravchenko Yu. A., Mansur A., et al. Algoritm optimizatsii izvlecheniya klyuchevykh slov na osnove primeneniya lingvisticheskogo parsera [Algorithm for Optimization of Keyword Extraction Based on the Application of a Linguistic Parser], *Informatika i avtomatizatsiya [Informatics and Automation]*, 2024, Vol. 23, No. 2, Pp. 467–494. DOI: 10.15622/ia.23.2.6. (In Russian)
15. Li X., Sigov A., Ratkin L., et al. Artificial Intelligence Applications in Finance: A Survey, *Journal of Management Analytics*, 2023, Vol. 10, Iss. 4, Pp. 676–692. DOI: 10.1080/23270012.2023.2244503.
16. Joshi N., Dave T. Improved Accuracy for Heart Disease Diagnosis Using Machine Learning Techniques, *Journal of Informatics and Web Engineering*, 2025, Vol. 4, No. 1, Pp. 42–52. DOI: 10.33093/jiwe.2025.4.1.4.
17. Datilo P. M., Ismail Z., Dare J. A Review of Epidemic Forecasting Using Artificial Neural Networks, *Epidemiology and Health System Journal*, 2019, Vol. 6, Iss. 3, Pp. 132–143. DOI: 10.15171/ijer.2019.24.
18. Atan O., Jordon J., van der Schaar M. Deep-Treat: Learning Optimal Personalized Treatments from Observational Data Using Neural Networks, *Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence, New Orleans, LA, USA, February 02–07, 2018*. Palo Alto (CA), AAAI Press, 2018, Pp. 2071–2078. DOI: 10.1609/aaai.v32i1.11841.
19. Li C., Wang Y., Bai H., et al. Deep Neural Network Provides Personalized Treatment Recommendations for *de novo* Metastatic Breast Cancer Patients, *Journal of Cancer*, 2024, Vol. 15, Iss. 20, Pp. 6668–6685. DOI: 10.7150/jca.101293.
20. Widayani A., Putra A. M., Maghriebe A. R., et al. Review of Application YOLOv8 in Medical Imaging, *Indonesian Applied Physics Letters*, 2024, Vol. 5, No. 1, Pp. 23–33. DOI: 10.20473/iapl.v5i1.57001.
21. Mumali F. Artificial Neural Network-Based Decision Support Systems in Manufacturing Processes: A Systematic Literature Review, *Computers and Industrial Engineering*, 2022, Vol. 165, Art. No. 107964, 20 p. DOI: 10.1016/j.cie.2022.107964.
22. Ribeiro J., Lima R., Eckhardt T., Paiva S. Robotic Process Automation and Artificial Intelligence in Industry 4.0 — A Literature Review, *Procedia Computer Science*, 2021, Vol. 181, Pp. 51–58. DOI: 10.1016/j.procs.2021.01.104.
23. Edelev D. A., Blagoveshchenskaya M. M., Blagoveshchenskiy I. G. Ispolzovanie neyronnykh setey kak faktora povysheniya kachestva i bezopasnosti proizvodstva pishchevykh produktov pri reshenii zadach avtomatizatsii [Using neural networks as a factor in improving the quality and safety of food production in solving automation problems], *Avtom-*

atizatsiya tekhnologicheskikh i biznes-protsessov [Automation of Technological and Business Processes], 2015, Vol. 7, No. 1 (21), Pp. 7–10. DOI: 10.15673/2312-3125.21/2015.42856. (In Russian)

24. Akhatova A. PCB Defects, *Kaggle*. Available at: <http://www.kaggle.com/datasets/akhatova/pcb-defects> (accessed: January 17, 2025).

25. Cheremisinova O. N., Rostovtsev V. S. Povyshenie kachestva raspoznavaniya izobrazheniy podborom parametrov svertochnoy neyronnoy seti [Improving the quality of image recognition by selecting convolutional neural network parameters], *Integratsiya nauki v sovremennom mire: sbornik nauchnykh rabot 52-y Mezhdunarodnoy nauchnoy konferentsii Evraziyskogo Nauchnogo Obedineniya [Integration of Science in the Modern World: Scientific Articles Collection of the 52nd International Scientific Conference of Eurasian Scientific Association]*, Moscow, Russia, June 2019. Moscow, Eurasian Scientific Association, 2019, Pp. 114–118. (In Russian)

26. Sirisha U., Praveen S. P., Srinivasu P. N., et al. Statistical Analysis of Design Aspects of Various YOLO-Based Deep Learning Models for Object Detection, *International Journal of Computational Intelligence Systems*, 2023, Vol. 16, Art. No. 126, 29 p. DOI: 10.1007/s44196-023-00302-w.

27. Ultralytics YOLO. Available at: <http://www.ultralytics.com/yolo> (accessed: January 17, 2025).

28. Redmon J., Divvala S., Girshick R., Farhadi A. You Only Look Once: Unified, Real-Time Object Detection, *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, June 27–30, 2016*. Institute of Electrical and Electronics Engineers, 2016, Pp. 779–788. DOI: 10.1109/CVPR.2016.91.

29. Google Colaboratory. Available at: <http://colab.google> (accessed: January 17, 2025).

30. F1-Score, *Ultralytics*. URL: <http://www.ultralytics.com/glossary/f1-score> (accessed: January 17, 2025).

Received: 26.03.2025

Accepted: 15.05.2025