

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КОНТРОЛЯ ПЕЧАТНЫХ ПЛАТ С ПОМОЩЬЮ ДАННЫХ РЕНТГЕНОВСКОГО 3D-МИКРОТОМОГРАФА

© 2025 г. В.И. Сырямкин^{1,*}, Ф.А. Классен¹, А.Н. Берцун¹

¹Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский Томский государственный университет», Россия
634050 Томск, пр-т Ленина, 36
E-mail: *svi_tsu@mail.ru

Поступила в редакцию 05.09.2024; после доработки 28.10.2024

Принята к публикации 29.10.2024

Рассматривается метод распознавания дефектов печатных плат с использованием нейронных сетей. Проводится анализ различных архитектур нейронных сетей для выявления наиболее эффективной. Также представлен подход к фильтрации данных, имитирующих работу микротомографа, с использованием сверточных автоэнкодеров. Для оценки качества предложенных подходов использовалась метрика mean Average Precision (mAP) для моделей YOLOv8 и Faster R-CNN.

Ключевые слова: нейронные сети, печатная плата, дефекты, фильтрация данных.

APPLICATION OF NEURAL NETWORKS FOR CONTROL OF PRINTED CIRCUIT BOARDS USING 3D X-RAY MICROTOMOGRAPHY DATA

© 2025 V.I. Syryamkin^{1,*}, F.A. Klassen¹, A.N. Bertsun¹

¹The National Research Tomsk State University, TSU, Russia 634050 Tomsk,
Lenin str., 36
E-mail: *svi_tsu@mail.ru

The article discusses a method for detecting PCB defects using neural networks. The analysis of various neural network architectures is carried out to identify the most effective. An approach to filtering data simulating the operation of a microtomograph using convolutional autoencoders is also presented. To assess the quality of the proposed approaches, the mean Average Precision (mAP) metric for the YOLOv8 and Faster R-CNN models was used.

Keywords: neural networks, printed circuit board, defects, data filtering.

DOI: 10.31857/S0130308225010058

ВВЕДЕНИЕ

В современном мире технологии развиваются с высокой скоростью, и печатные платы являются неотъемлемой частью многих электронных устройств. Они представляют собой сложные многослойные структуры, которые требуют тщательного контроля качества перед сборкой и установкой в конечное изделие. Одним из наиболее эффективных инструментов, используемых в задаче поиска дефектов печатных плат, являются нейронные сети [1—4].

Нейронные сети — это математические модели, основанные на принципах работы биологических нейронных систем (рис. 1). Они способны обучаться на больших объемах данных и находить сложные зависимости в них. В контексте поиска дефектов на печатных платах нейронные сети могут быть обучены распознавать различные типы дефектов, такие как короткие замыкания, обрывы, дефекты пайки и другие.

Целью данной статьи является обзор существующих методов поиска дефектов с помощью нейронных сетей, анализ их преимуществ и недостатков, а также разработка и исследование новых подходов к повышению эффективности и точности детектирования и распознавания дефектов печатных плат. Результаты исследования могут быть полезны для специалистов в области электроники, разработчиков программного обеспечения и исследователей, занимающихся вопросами автоматизации процессов контроля качества, печатных плат и элементов радиоэлектронной аппаратуры.

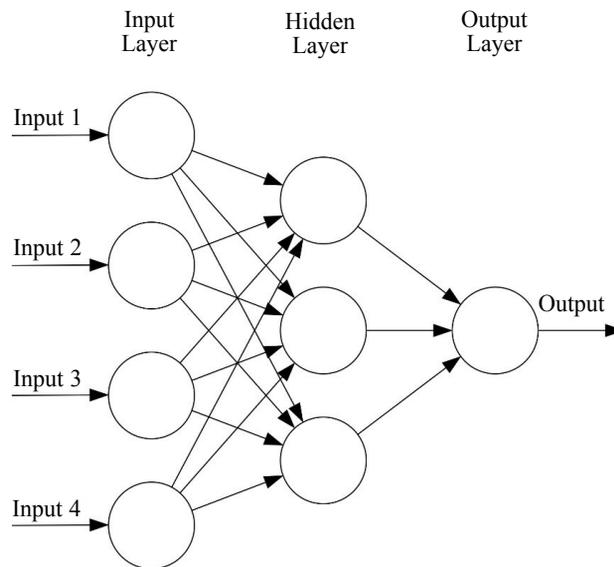


Рис. 1. Модель нейронной сети.

ОБЗОР

Развитие глубокого обучения привело к разработке бесконтактных методов автоматического детектирования, которые стали популярной областью исследований благодаря их высокой адаптивности к распознаванию и способности к обобщению [5]. Как правило, нейронные сети, пригодные для использования в задаче распознавания дефектов на изображениях, можно разделить на одноэтапные и двухэтапные. «Вы смотрите только один раз» («You Only Look Once» (YOLO)) — одна из самых популярных архитектур моделей и алгоритмов детектирования и распознавания объектов на изображениях или в видеопотоке (рис. 2) [6—9]. Она использует одну из лучших архитектур нейронных сетей для обеспечения высокой точности и общей скорости обработки, что является основной причиной его популярности. Примерами двухэтапных сетей являются Fast R-CNN и Faster R-CNN (рис. 3) [10, 11], которые представляют собой улучшенные версии более ранней модели — R-CNN [12]. Основное различие между этими сетями заключается в том, что одноэтапная сеть напрямую прогнозирует местоположение и категорию дефектов в сети после извлечения признаков, тогда как двухэтапная сеть сначала генерирует предложения, которые могут включать дефекты, а затем проводит процесс распознавания. В частности, двухэтапная сеть генерирует блоки-кандидаты разных размеров, которые могут содержать признаки дефекта, а затем выполняет распознавание целей для прогнозирования классов и местоположений дефектов. Однако скорость распознавания в таком случае довольно низкая из-за генерации множества кадров-кандидатов. С другой стороны, одноэтапная сеть выполняет как обучение, так и распознавание в одной сети без необходимости явного предложения потенциальных регионов, что приводит к более высокой скорости распознавания. В этой статье используется одноэтапная сеть на основе YOLOv8 и двухэтапная Faster R-CNN.

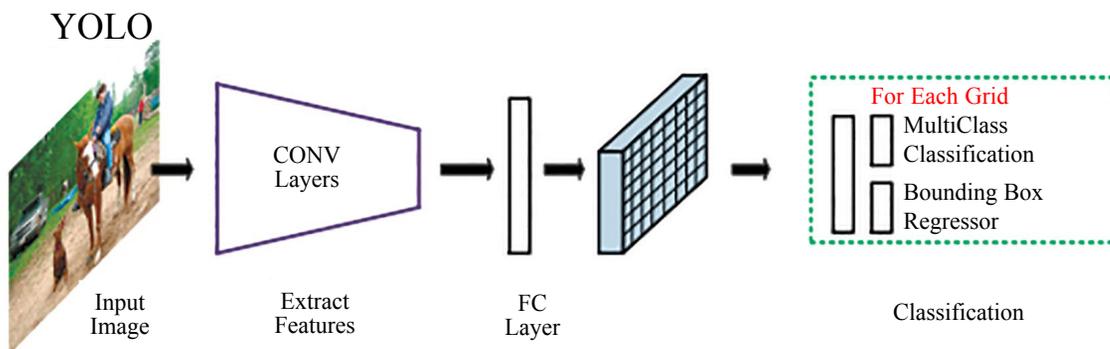


Рис. 2. Архитектура YOLO, изображение взято из работы «Deep Learning for Generic Object Detection: A Survey» [13].

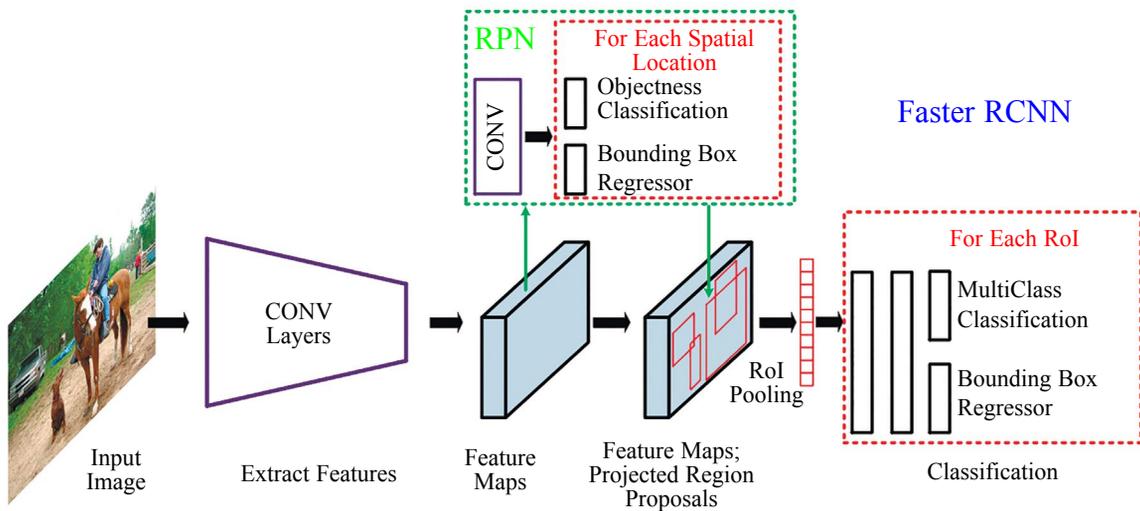


Рис. 3. Архитектура Faster RCNN, изображение взято из работы «Deep Learning for Generic Object Detection: A Survey» [13].

ДААННЫЕ

Были изготовлены печатные платы по технологии ЛУТ (лазерно-утюжная технология). Суть метода ЛУТ заключается в том, что изображение платы распечатывается на глянцевой фотобумаге и прижигается к плате при помощи обычного утюга. В дальнейшем бумага размачивается в воде и скатывается с текстолита. На текстолите остаются чернила, которые ранее были на бумаге. Полученный кусочек текстолита замачивается в растворе хлорного железа. Хлорное железо растворяет всю медь, которая не располагается под чернилами. По окончании чернила смываются и в результате имеем под ними сохранившиеся дорожки из меди, как представлено на рис. 4.

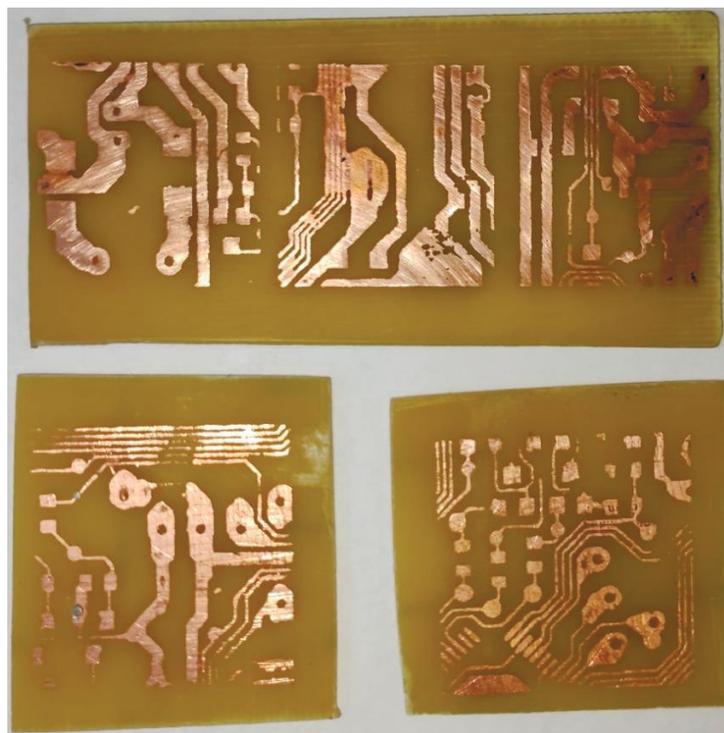


Рис. 4. Примеры изготовленных печатных плат.

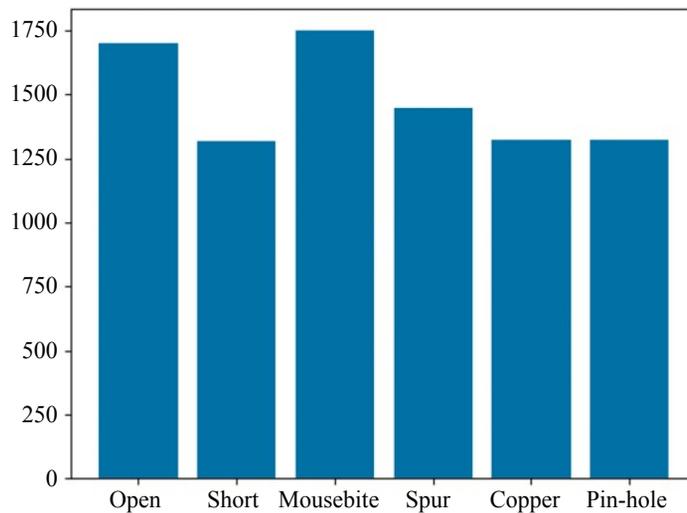


Рис. 5. Количество дефектов каждого типа в представленном наборе данных (здесь на оси абсцисс указаны название дефектов, а на оси ординат — общее количество дефектов конкретного типа).

В качестве данных для обучения использовался набор изображений участков печатных плат, собранных в Shanghai Jiao Tong University [14]. Печатные платы, изготовленные методом ЛУТ, были отсканированы при помощи микротомографа [15—18], и на их основе была произведена компьютерная имитация работы микротомографа путем добавления случайных шумов и применения размытия к изображениям из вышеупомянутого набора данных.

Процедура создания зашумленного изображения включает в себя следующие шаги:

1. Исходное изображение объединяется с серым фоном с помощью заданного уровня прозрачности. Затем изменяется яркость и контрастность, добавляется случайный шум и применяется размытие.

2. На заключительном этапе выполняется выравнивание гистограммы и глобальная нормализация контраста, чтобы получить конечное изображение.

Представленный набор содержит 1500 изображений участков печатных плат, а каждое изображение имеет разрешение 640×640 пикселей. В процессе обучения данные разбивались на тренировочную и валидационную выборки в соотношении 4:1.

Всего было представлено 6 типов дефектов:

- Open (разрыв);
- Short (замыкание);
- Mousebite (вырыв);
- Spur (выступ);
- Copper (остров);
- Pin-hole (прокол).

МОДЕЛИ

Для сравнения были выбраны две архитектуры сверточных нейронных сетей — YOLOv8 и Faster R-CNN (ResNet-50-FPN backbone). Обучение моделей производилось на одинаковом оборудовании — персональный компьютер с установленными процессором Intel Core i9-12900kf и видеокартой — NVIDIA RTX 3090.

ФУНКЦИИ ПОТЕРЬ

В качестве функций потерь для модели YOLOv8 и Faster R-CNN применяли несколько различающиеся функции потерь, предложенные авторами данных архитектур. Так для Faster R-CNN использовалась функция потерь, представленная суммой других четырех функций потерь:

$$L = L_{classifier} + L_{box_reg} + L_{objectness} + L_{rpm_box_reg}, \quad (1)$$

где $L_{classifier}$ — ошибка классификации; L_{box_reg} — регрессионная ошибка; $L_{objectness}$ — ошибка достоверности распознавания объекта; $L_{rpm_box_reg}$ — регрессионная ошибка отдельной части

нейронной сети — Region Proposal Network (RPN), отвечающей за генерацию потенциальных мест, содержащих искомые объекты.

Для YOLOv8 функция потерь вычисляется как взвешенная сумма трех различных функций:

$$L = w_1 \cdot L_{box} + w_2 \cdot L_{cls} + w_3 \cdot L_{dfl}, \tag{2}$$

где L_{box} — ошибка регрессии; L_{cls} — ошибка классификации; L_{dfl} — ошибка смещения ограничивающей рамки; w_1, w_2, w_3 — соответствующие им веса.

ИСПОЛЬЗОВАННЫЕ МЕТРИКИ КАЧЕСТВА МОДЕЛЕЙ

Для сравнения результатов работы моделей использовалась метрика mAP (Mean-Average-Precision). Значение mAP измеряется в диапазоне от 0 до 1 и равно среднему значению показателя средней точности по всем классам, а вычислить его можно следующим образом:

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i, \tag{3}$$

где AP_i определяется как площадь под кривой precision-recall [19] для класса под номером i , а n обозначает общее количество классов. В данной работе выбранная метрика будет указываться вместе с числом (например, mAP50 или mAP50-95), представляющим порог значения IoU (Intersection over Union). Intersection over Union — число, представляющее собой отношение «площади пересечения» к «площади объединения» между прогнозируемой и истинной ограничивающими рамками объекта. Таким образом, в дальнейшем тексте работы запись «mAP50» будет значить, что метрика вычислялась с учетом порога IoU, равным 0,5 (50 %), а запись «mAP50-95» — что метрика вычислялась при разных порогах от 0,5 до 0,95 (от 50 до 95 %) с шагом 0,05, а затем находилось усредненное значение.

ОБУЧЕНИЕ И РЕЗУЛЬТАТЫ НА ЗАШУМЛЕННЫХ ДАННЫХ

В результате обучения обеих моделей на описанных данных удалось получить следующие результаты, указанные в табл. 1.

Таблица 1

Результаты моделей на зашумленных данных

Модель	Класс дефекта	mAP50
YOLOv8	Open	0,9
	Short	0,76
	Mousebite	0,81
	Spur	0,82
	Copper	0,91
	Missing_hole	0,86
Faster R-CNN	Open	0,93
	Short	0,87
	Mousebite	0,86
	Spur	0,91
	Copper	0,95
	Missing_hole	0,94

ФИЛЬТРАЦИЯ ДАННЫХ

После анализа полученных результатов было выдвинуто предположение, что очистка данных от шумов может повысить качество распознавания дефектов.

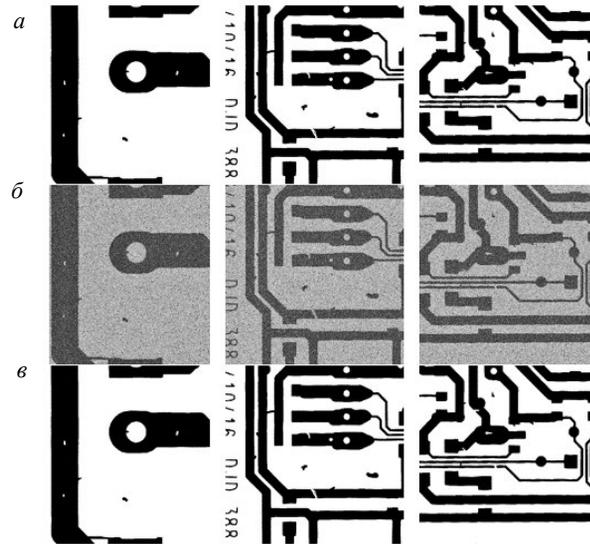


Рис. 6. Сравнение результатов работы автоэнкодера: *а* — оригинальные изображения; *б* — зашумленные изображения; *в* — изображения, очищенные при помощи автоэнкодера.

В качестве инструмента для удаления шумов было выбрано использование сверточного автоэнкодера [20—23].

При помощи библиотеки Keras [24] была реализована архитектура сверточного автоэнкодера, принимающего на вход и предоставляющего на выходе изображения разрешением 320×320 пикселей.

Для обработки изображений большего разрешения, чем 320×320 пикселей, использовался алгоритм разбиения изображения на отдельные части, с последующей их обработкой и обратным соединением с наложением (для избежания появления нежелательных артефактов на границе стыка частей) [25].

Итоговая структурная схема получившегося программного обеспечения изображена на рис. 7.

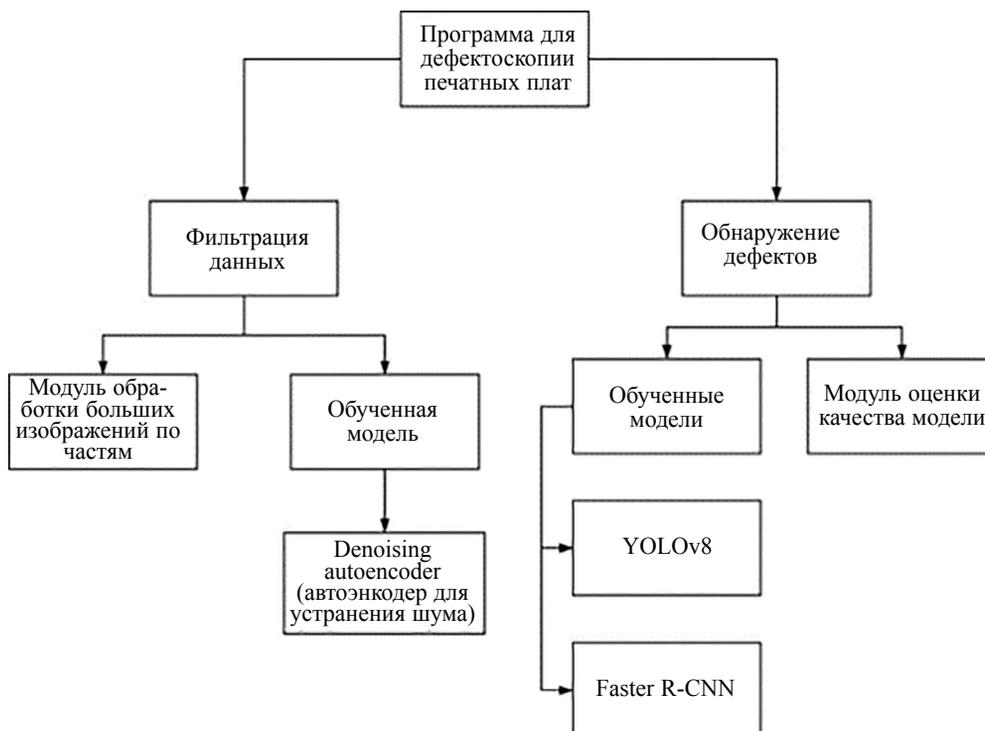


Рис. 7. Структурная схема программного обеспечения.

ОБУЧЕНИЕ И РЕЗУЛЬТАТЫ НА ОЧИЩЕННЫХ ДАННЫХ

Параметры моделей были в точности идентичны тем, которые были использованы для обучения на зашумленных данных.

Полученные результаты изображены в табл. 2.

Таблица 2

Результаты моделей на очищенных данных

Модель	Класс дефекта	mAP50
YOLOv8	Open	0,98
	Short	0,96
	Mousebite	0,97
	Spur	0,97
	Copper	0,99
	Missing_hole	0,99
	Open	0,95
Faster R-CNN	Short	0,94
	Mousebite	0,93
	Spur	0,95
	Copper	0,97
	Missing_hole	0,97

Сравнение результатов для зашумленных и очищенных данных приведены в табл. 3.

Таблица 3

Сравнение результатов моделей на зашумленных и очищенных данных

Модель	Данные	mAP50	mAP50-95
YOLOv8	Зашумленные	0,84	0,46
	Очищенные	0,98	0,76
Faster R-CNN	Зашумленные	0,91	0,62
	Очищенные	0,95	0,70

ЗАКЛЮЧЕНИЕ

В статье представлен метод распознавания дефектов печатных плат с помощью нейронных сетей YOLOv8 и Faster R-CNN. Эксперименты проводились как на наборе из незашумленных изображений, так и на наборе, имитирующем зашумленные данные микротомографа.

Для зашумленных данных архитектура Faster R-CNN показала себя несколько лучше, а на очищенных данных обе модели показали значительный прирост результатов, с небольшим преимуществом архитектуры YOLO. Поэтому можно говорить о применимости описанного метода очистки изображений от шумов для повышения качества распознавания дефектов.

Таким образом, можно сделать вывод о том, что нейронные сети могут быть эффективным инструментом для применения в задаче контроля качества электронных печатных плат.

Исследование выполнено за счет гранта Российского научного фонда № 22-19-00389, <https://rscf.ru/project/22-19-00389/>

СПИСОК ЛИТЕРАТУРЫ

1. Иваненко Б.П., Клестов С.А., Сыряжкин В.И. Сравнение нейросетевых методов предобработки данных при решении задач анализа, диагностики и классификации дефектов радиоэлектронной аппаратуры // Автометрия. 2023. Т. 59. № 2. С. 17—24.

2. Левкевич В.И., Иваненко Б.П., Клецов С.А. Классификация дефектов поверхности печатных плат нейросетевыми методами / Инноватика-2023. Сб. материалов XIX Международной школы-конференции студентов, аспирантов и молодых ученых. Томск, 2023. С. 232—234.
3. Цвингер В.А., Сыряжкин В.И., Клецов С.А. Использование систем технического зрения в контроле качества печатных плат / Инноватика-2023. Сб. материалов XIX Международной школы-конференции студентов, аспирантов и молодых ученых. Томск, 2023. С. 225—228.
4. Alghassab M.A. Defect detection in printed circuit boards with pre-trained feature extraction methodology with convolution neural networks // Computers, Materials & Continua. 2022. V. 70. No 1. P. 637—652.
5. Adibhatla V.A., Shieh J.S., Abbod M.F., Chih H.C., Hsu C.C., Cheng J. Detecting Defects in PCB using Deep Learning via Convolution Neural Networks / 2018 13th International Microsystems, Packaging, Assembly and Circuits Technology Conference (IMPACT), Taipei, Taiwan. 2018. P. 202—205.
6. Chen W., Huang Z., Mu Q., Sun Y. PCB Defect Detection Method Based on Transformer-YOLO // IEEE Access. 2022. V. 10. P. 129480—129489.
7. Terven Juan, Cordova-Esparza Diana-Margarita, Romero-González Julio-Alejandro. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS // Machine Learning and Knowledge Extraction. 2023. V. 5. No 4. P. 1680—1716.
8. Yujie Yang, Haiyan Kang. An Enhanced Detection Method of PCB Defect Based on Improved YOLOv7 // Electronics. 2023. V. 12. No. 9. P. 2120.
9. Adibhatla V.A., Chih H.C., Hsu C.C., Cheng J., Abbod M.F., Shieh J.S. Defect Detection in Printed Circuit Boards Using You-Only-Look-Once Convolutional Neural Networks // Electronics. 2020. V. 9. No. 9.
10. Girshick R. Fast R-CNN / 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile. 2015. P. 1440—1448.
11. Shaoqing Ren, He Kaiming, Girshick Ross, Sun Jian. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2016. V. 39. No. 6. P. 1137—1149.
12. Girshick R., Donahue J., Darrell T., Mali J. Rich feature hierarchies for accurate object detection and semantic segmentation / Proceedings of the IEEE conference on computer vision and pattern recognition. 2014. P. 580—587.
13. Liu L., Ouyang W., Wang X., Fieguth P., Chen J., Liu X., Pietikäinen M. Deep learning for generic object detection: A survey // International journal of computer vision. 2020. V. 128. P. 261—318.
14. Tang S., He F., Huang X., Yang J. Online PCB defect detector on a new PCB defect dataset // arXiv preprint arXiv:1902.06197. 2019.
15. Syryamkin V.I., Klestov S.A., Sunstov S.B., Ivanenko B.P., Levkevich V.I. Digital X-ray Tomography. London: Red Square Scientific, 2023. 296 p.
16. Сыряжкин В.И., Клецов С.А., Суницев С.Б. Проектирование рентгеновского 3D-микротомографа на основе его «цифрового двойника» // Дефектоскопия. 2022. № 11. С. 56—65.
17. Хильчук М.Д., Клецов С.А. Рентгеновская цифровая томография для диагностики элементов радиоэлектронной аппаратуры / Инноватика-2023. Сб. материалов XIX Международной школы-конференции студентов, аспирантов и молодых ученых. Томск, 2023. С. 229—231.
18. Миникаев Р.Р., Клецов С.А. Разработка математической модели и программного обеспечения для дефектоскопии снимков интеллектуального рентгеновского 3d микротомографа на основе нейро-нечеткого метода анализа, диагностики и классификации дефектов радиоэлектронной аппаратуры / Инноватика-2022. Сб. материалов XVIII международной школы-конференции студентов, аспирантов и молодых ученых. Томск, 2022. С. 184—187.
19. Davis J., Goadrich M. The relationship between Precision-Recall and ROC curves / Proceedings of the 23rd international conference on Machine learning. 2006. P. 233—240.
20. Venkataraman P. Image denoising using convolutional autoencoder // arXiv preprint arXiv:2207.11771. 2022.
21. Baldi P. Autoencoders, unsupervised learning, and deep architectures / Proceedings of ICML workshop on unsupervised and transfer learning. JMLR Workshop and Conference Proceedings. 2012. P. 37—49.
22. Kim J., Ko J., Choi H., Kim H. Printed circuit board defect detection using deep learning via a skip-connected convolutional autoencoder // Sensors. 2021. V. 21. No. 15. P. 4968.
23. Zhao G., Liu J., Jiang J., Guan H., Wen J.R. Skip-connected deep convolutional autoencoder for restoration of document images / 2018 24th International Conference on Pattern Recognition (ICPR). 2018. P. 2935—2940.
24. Keras. URL: <https://keras.io/>
25. Документ № 2024663941. Программа для фильтрации изображений на основе нейросетевых алгоритмов для диагностики печатных плат и РЭА (ПЭВМ).

REFERENCES

1. Ivanenko B.P., Klestov S.A., Syryamkin V.I. Comparison of neural network methods of data preprocessing in solving problems of analysis, diagnosis, and classification of defects of radio-electronic equipment // Avtometriya. 2023. V. 59. No. 2. P. 17—24.

2. *Levkevich V.I., Ivanenko B.P., Klestov S.A.* Classification of printed circuit board surface defects by neural network methods / Innovation-2023. The XIX International School-Conference of Students, Graduate Students and Young Scientists, Tomsk, Russia. 2023. P. 232—234.
3. *Tsvinger V.A., Syryamkin V.I., Klestov S.A.* Application of machine vision in quality control of printing covers / Innovation-2023. The XIX International School-Conference of Students, Graduate Students and Young Scientists, Tomsk, Russia. 2023. P. 225—228.
4. *Alghassab M.A.* Defect detection in printed circuit boards with pre-trained feature extraction methodology with convolution neural networks // Computers, Materials & Continua. 2022. V. 70. No. 1. P. 637—652.
5. *Adibhatla V.A., Shieh J.S., Abbod M.F., Chih H.C., Hsu C.C., Cheng J.* Detecting Defects in PCB using Deep Learning via Convolution Neural Networks / 2018 13th International Microsystems, Packaging, Assembly and Circuits Technology Conference (IMPACT), Taipei, Taiwan. 2018. P. 202—205.
6. *Chen W., Huang Z., Mu Q., Sun Y.* PCB Defect Detection Method Based on Transformer-YOLO // IEEE Access. 2022. V. 10. P. 129480—129489.
7. *Terven Juan, Cordova-Esparza Diana-Margarita, Romero-González Julio-Alejandro.* A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS // Machine Learning and Knowledge Extraction. 2023. V. 5. No. 4. P. 1680—1716.
8. *Yujie Yang, Haiyan Kang.* An Enhanced Detection Method of PCB Defect Based on Improved YOLOv7 // Electronics. 2023. V. 12. No. 9. P. 2120.
9. *Adibhatla V.A., Chih H.C., Hsu C.C., Cheng J., Abbod M.F., Shieh J.S.* Defect Detection in Printed Circuit Boards Using You-Only-Look-Once Convolutional Neural Networks // Electronics. 2020. V. 9. No. 9.
10. *Girshick R.* Fast R-CNN / 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile. 2015. P. 1440—1448.
11. *Shaoqing Ren, He Kaiming, Girshick Ross, Sun Jian.* Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2016. V. 39. No. 6. P. 1137—1149.
12. *Girshick R., Donahue J., Darrell T., Mali J.* Rich feature hierarchies for accurate object detection and semantic segmentation / Proceedings of the IEEE conference on computer vision and pattern recognition. 2014. P. 580—587.
13. *Liu L., Ouyang W., Wang X., Fieguth P., Chen J., Liu X., Pietikäinen M.* Deep learning for generic object detection: A survey // International journal of computer vision. 2020. V. 128. P. 261—318.
14. *Tang S., He F., Huang X., Yang J.* Online PCB defect detector on a new PCB defect dataset // arXiv preprint arXiv:1902.06197. 2019.
15. *Syryamkin V.I., Klestov S.A., Suntsov S.B., Ivanenko B.P., Levkevich V.I.* Digital X-ray Tomography // London: Red Square Scientific. 2023. 296 p.
16. *Syryamkin V.I., Klestov S.A., Suncov S.B.* Design of 3d x-ray microtomograph based on its «digital twin» // Defektoskopiya. 2022. No. 11. P. 56—65.
17. *Khilchuk M.D., Klestov S.A.* X-ray digital tomography for diagnostics of radio-electronic equipment elements / Innovation-2023. The XIX International School-Conference of Students, Graduate Students and Young Scientists, Tomsk, Russia. 2023. P. 229—231.
18. *Minikaev R.R., Klestov S.A.* Development of a mathematical model and software for defectoscopy of images of an intelligent x-ray 3d microtomograph based on the neuro-fuzzy method of analysis, diagnosis and classification of defects in radio electronic equipment / Innovation-2022. The XVIII International School-Conference of Students, Graduate Students and Young Scientists Tomsk, Russia. 2022. P. 184—187.
19. *Davis J., Goadrich M.* The relationship between Precision-Recall and ROC curves / Proceedings of the 23rd international conference on Machine learning. 2006. P. 233—240.
20. *Venkataraman P.* Image denoising using convolutional autoencoder // arXiv preprint arXiv:2207.11771. 2022.
21. *Baldi P.* Autoencoders, unsupervised learning, and deep architectures / Proceedings of ICML workshop on unsupervised and transfer learning. JMLR Workshop and Conference Proceedings. 2012. P. 37—49.
22. *Kim J., Ko J., Choi H., Kim H.* Printed circuit board defect detection using deep learning via a skip-connected convolutional autoencoder // Sensors. 2021. V. 21. No. 15. P. 4968.
23. *Zhao G., Liu J., Jiang J., Guan H., Wen J.R.* Skip-connected deep convolutional autoencoder for restoration of document images / 2018 24th International Conference on Pattern Recognition (ICPR). 2018. P. 2935—2940.
24. Keras. URL: <https://keras.io/>
25. Document № 2024663941. A program for image filtering based on neural network algorithms for the diagnosis of printed circuit boards and REA (PC).