

УДК 004.932.2

ОБНАРУЖЕНИЕ ДЕФЕКТОВ ПЕЧАТНЫХ ПЛАТ НА ИЗОБРАЖЕНИЯХ

В. В. Венгеренко, А. В. Инютин

*Объединенный институт проблем информатики Национальной академии наук Беларусь,
Минск, Беларусь, vengerenko@lsi.bas-net.by, avin@newman.bas-net.by*

В мире наблюдается тенденция к использованию одностадийных детекторов и их облегченных версий, таких как YOLOv8, Faster R-CNN, RT-DETR и их модификации, для обнаружения дефектов печатных плат. Нейросетевые детекторы показывают высокую точность результатов даже при наличии бликов, защитного лака и текстовой информации на плате. В докладе рассмотрены современные нейросетевые детекторы дефектов печатных плат, классический алгоритмом сравнения с эталоном и гибридный подход на его основе. Предложенная модель YOLOv8n, дообученная на открытых датасетах DeepPCB и PCB Defect Dataset, демонстрирует значения mAP50 0,98 и 0,99, что сопоставимо или превосходит лучшие мировые результаты.

Ключевые слова: печатная плата; нейронная сеть; компьютерное зрение; обнаружение; ограничивающий прямоугольник.

PRINTED CIRCUIT BOARD DEFECTS DETECTION IN IMAGES

V. V. Vengerenko, A. V. Inyutin

*The United Institute of Informatics Problems of the National Academy of Sciences of Belarus,
Minsk, Belarus, vengerenko@lsi.bas-net.by, avin@newman.bas-net.by*

There is a global trend towards the use of one-stage detectors and their lightweight versions, such as YOLOv8, Faster R-CNN, RT-DETR and their modifications, to detect printed circuit board (PCB) defects. Neural network detectors show high accuracy of results even in the presence of glare, protective varnish and text information on the PCB. This paper examines modern neural network detectors of PCB defects, the classic reference-based PCB inspection algorithm and the hybrid approach based on it. The proposed YOLOv8n model, further trained on open datasets DeepPCB and PCB Defect Dataset, demonstrates the mAP50 values of 0.98 and 0.99, which is comparable or exceeds the best global results.

Keywords: printed circuit board; neural network; computer vision; detection; bounding box.

1. Введение

Важной проблемой при производстве радиоэлектронного оборудования является контроль качества печатных плат на различных технологических этапах. Объектом для контроля будет являться изображение печатной платы или ее фотошаблона. Элементами на изображении печатной платы

будут являться контактные площадки, проводники, реперные точки, служебная информация в виде букв и цифр. Дефектом при осуществлении контроля является отклонение элементов топологии на объекте от проектной документации вследствие погрешностей при производстве. Актуальность задачи поиска дефектов печатных плат обусловлена использованием новых элементов, материалов и технологий их производства [1].

2. Предлагаемые методы

Алгоритм сравнения с эталоном

Данный алгоритм заключается в следующем. Вначале производится предварительная обработка изображения, которая состоит из бинаризации, удаления шума, коррекции масштаба и угла поворота для совмещения эталона и анализируемого изображения. Далее производится поиск дефектов с помощью операции «Исключающее ИЛИ». Найденные дефекты классифицируются по бинарным флагам, определяются их геометрические параметры.

Модель YOLOv8

YOLOv8 – современная модель классификации изображений, сегментации экземпляров и обнаружения объектов без привязки, разработанная Ultralytics. Модели YOLOv8 можно обучать на больших наборах данных и запускать на различных аппаратных платформах. Одной из ключевых особенностей YOLOv8 является расширяемость. Она поддерживает все предыдущие версии YOLO, что позволяет легко переключаться между различными версиями и сравнивать их производительность.

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

Гибридный подход

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 [1]. 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.

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 [1]:

- 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 ис-

пользоваться 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 [1].

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 изображения. Эти факторы непосредственно влияют на качество поиска дефектов.

3. Обсуждение результатов

В первой части экспериментов модель YOLOv8 размера nano, предобученная на наборе данных COCO, была дообучена и протестирована на наборе изображений DeepPCB. 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. Алгоритм сравнения с эталоном использует бинаризацию методом Оцу и морфологические операции отмыкания и замыкания с круглым структурирующим элементом размерами 3×3 и 5×5 . Алгоритм сравнения с эталоном использует семантический фильтр, отсеивающий дефекты площадью менее 20 пикселов.

Результаты экспериментов, представленные в табл. 1, 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%.

Таблица 1

Сравнение результатов поиска и классификации дефектов на наборе данных DeepPCB

Метод	Число дефектов	Метрика оценки			
		Precision	Recall	F1-score	Accuracy
YOLOv8n	11 768	0,768	0,847	0,805	0,847
Сравнение с эталоном	11 712	0,718	0,755	0,731	0,755
Гибридный	14 359	0,625	0,767	0,685	0,767

На рис. 1 показан пример обнаружения дефектов печатных плат с помощью предлагаемого гибридного подхода на изображениях из набора данных DeepPCB.

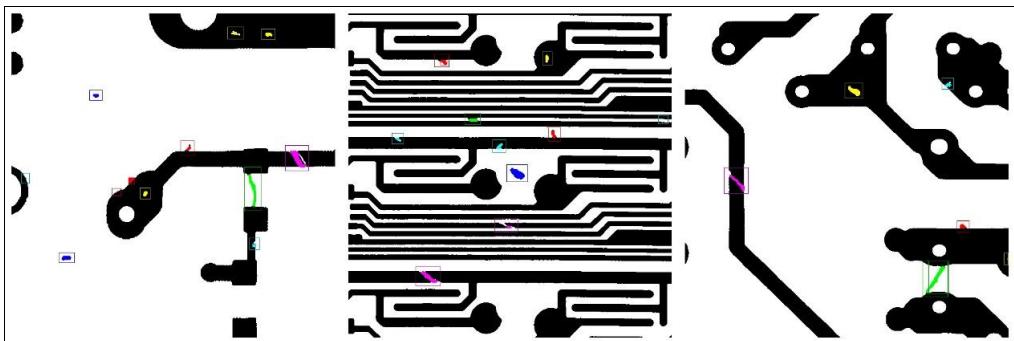


Рис. 1. Обнаружение дефектов печатных плат с помощью гибридного подхода на изображениях из набора данных DeepPCB

Полученная точность детекции дефектов печатных плат сравнима с лучшими мировыми результатами (табл. 2):

- SSD – одностадийный метод обнаружения объектов, который выполняет детекцию и классификацию в одном проходе нейросети без генерации предложений регионов [2]. Средняя точность (mAP) – 95,9%;

- YOLO – одностадийный метод детекции объектов, в котором сверточная сеть одновременно предсказывает координаты ограничивающих рамок и классы объектов, что позволяет выполнять детекцию за один проход по изображению [3]. Значение mAP – 92,6%;

- Faster R-CNN – архитектура обнаружения объектов, основанная на совместной работе сверточной сети генерации регионов-кандидатов (Region Proposal Network, RPN) и детектора извлечения признаков Fast R-CNN [4]. Значение mAP – 97,6%;

- нейросетевая модель с модулем улучшения контекста и семантики (Attentive Context and Semantic Enhancement Module, ACASEM) для обнаружения дефектов печатных плат с помощью двухступенчатых и многоступенчатых детекторов объектов [5]. Значение mAP – 79,5%;

– неконтролируемое обнаружение дефектов на изображениях печатных плат с учетом неопределенности и использованием реконструктивных и дискrimинационных моделей (U2D2PCB) на основе двух сетей U-Net, которые служат в качестве реконструктивной и дискrimинационной подсетей [6]. Значение mAP – 95,78%;

– модуль поиска дефектов печатных плат на основе группового пирамидального объединения (Group Pyramid Pooling, GPP), который извлекает признаки на разных масштабах и объединяет их по группам, что позволяет локализовать как мелкие, так и крупные дефекты [7]. Значение mAP – 98,6%.

Таблица 2

Сравнение результатов детекции дефектов для набора DeepPCB

Метод	Оценка результата	Метрика оценки
SSD [2]	95,9	mAP
YOLO [3]	92,6	mAP
Faster R-CNN [4]	97,6	mAP
Faster R-CNN + ACASEM [5]	79,5	mAP50-95
U2D2PCB [6]	95,78	mAP
GPP со средним объединением [7]	97,1	mAP
GPP с максимальным объединением [7]	98,6	mAP
YOLOv8n	98,0	mAP

Во второй части экспериментов модель YOLOv8 размера nano, предобученная на наборе данных DOTAv1 [8], была дообучена и протестирована на наборе изображений PCB Defect Dataset. 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. Алгоритм сравнения с эталоном использует глобальную бинаризацию – диапазону значения RGB от (0, 20, 0) до (45, 85, 45) соответствует белый цвет, ациальному диапазону – черный. Для совмещения тестируемого изображения и эталона используются масштабно-инвариантная трансформация признаков (Scale Invariant Feature Transform, SIFT) [9], сопоставление дескрипторов методом Brute-Force [10] и интерполяция методом ближайшего соседа [11]. Морфологические операции отмыкания-замыкания с круглым структурирующим элементом размером 5×5 применяются для сглаживания результатов бинаризации и совмещения.

Сравнение с результатами, доступными в открытой печати, приведено в табл. 3, из которой видно, что обученная модель YOLOv8n OBB показывает лучшую точность детекции дефектов печатных плат.

Таблица 3

**Сравнение результатов поиска дефектов печатных плат на наборе данных
PCB Defect Dataset, доступными в открытой печати**

Модель НС и ссылка на источник данных	Метрика оценки		
	mAP50, %	Precision, %	mAP50, %
Faster R-CNN [12]	84,5	87,3	92,7
YOLOv5 [12]	92,5	88,1	93,6
YOLOv7 [12]	94,7	89,3	94,3
YOLOv8s [12]	94,5	92,6	95,1
RT-DETR [12]	95,6	93,5	95,9
YOLO-BFRV [12]	98,4	96,9	98,2
YOLOv3 [13]	96,1	97,3	92,7
YOLOv5 [13]	97,7	98,8	95,5
YOLOv8 [13]	97,6	98,2	95,4
GCC-YOLO [13]	98,2	99,0	97,3
SCF-YOLO [14]	92,9	92,5	90,2
CDI-YOLO [15]	98,3	97,1	96,4
YOLOv8 [16]	97,6	98,6	94,7
YOLOv9 [16]	97,8	98,1	95,4
YOLOv10 [16]	98,0	98,9	94,4
YOLOv11 [16]	97,6	98,9	94,6
YOLO-SSW [16]	98,4	99,2	95,5
Faster R-CNN + ACASEM [5]	98,6	—	—
YOLOv8n OBB	99	99,5	98,8
Сравнение с эталоном	85,8	86,8	85,8

В табл. 3 представлены данные для следующих моделей нейронных сетей.

– Faster R-CNN [4] и RT-DETR (Real-Time DEtection TRansformer) [17] – современные архитектуры для обнаружения объектов в компьютерном зрении. DETR использует архитектуру трансформера, которая моделирует глобальные взаимосвязи между объектами и контекстом изображения без необходимости в заранее заданных связях.

– YOLO-BFRV – модифицированная версия алгоритма обнаружения объектов YOLO, разработанная для поиска дефектов на печатных платах [12]. Главные компоненты архитектуры – двунаправленная пирамидальная сеть признаков (Bidirectional Feature Pyramid Network, BiFPN); облегченная версия backbone-сети FasterNet; перепараметризованные детекторы (RepHead, Re-parameterized Detection Head); функция потерь Varifocal Loss.

– GCC-YOLO – модель, использующая модули глобального контекста (Global Context, GC) и улучшенное слияние признаков через BiFPN, что позволяет сохранить информацию о мелких деталях при углублении сети [13].

– SCF-YOLO – упрощенный метод детекции дефектов печатных плат с низкой вычислительной сложностью. Основана на более компактной MobileNet в качестве сети извлечения признаков для сокращения количества параметров модели и использовании SCF-блока (Spatial-Channel Fusion), объединяющего значимые пространственные признаки и выделяющего наиболее информативные каналы признаков, улучшая представление и фильтрацию релевантной информации [14].

– CDI-YOLO – модель обнаружения дефектов печатных плат, основанная на облегченной версии YOLOv7-tiny для компактности и высокой скорости работы [15]. Основные особенности CDI-YOLO – использование механизма координатного внимания (Coordinate Attention, CA). Части обычных сверток заменены на свертки, разделимые в глубину (depthwise separable convolution, DSConv). Используется модифицированная функция потерь Inner-CIoU для прогнозирования координат ограничивающих рамок, что ускоряет и улучшает точность локализации дефектов.

– YOLO-SSW – модель, основанная на версии YOLOv8 и использующая архитектуру YOLO-SPD-SimAM-WIoU [16]. SPD (Spatial Pyramid Decomposition) – модуль, обеспечивающий многоуровневое пространственное разложение признаков для детектирования объектов разных масштабов. SimAM (Simple Attention Module) – механизм внимания, который усиливает значимые признаки без значительных вычислительных затрат, улучшая выделение релевантной информации на сложных фонах. WIoU (Wise Intersection over Union) – улучшенная функция потерь для прогнозирования координат ограничивающих рамок, которая учитывает качество предсказания и динамически адаптируется, повышая точность локализации и ускоряя обучение.

На рис. 2 показан пример обнаружения дефектов печатных плат с помощью предлагаемой модели YOLOv8n OBB на изображениях из набора данных PCB Defect Dataset.

4. Заключение

В мире наблюдается тенденция к использованию одностадийных детекторов (YOLO, SSD) и их облегченных версий (SCF-YOLO, CDI-YOLO, YOLO-SSW), которые обеспечивают баланс между точностью и скоростью, что важно для реального производства с контролем продукции на конвейере. Такие модели используют компактные backbone-сети (MobileNet, FasterNet), облегченные свертки и оптимизированные функции потерь. Для повышения чувствительности к мелким и сложным дефектам активно внедряются модули пространственного и координатного

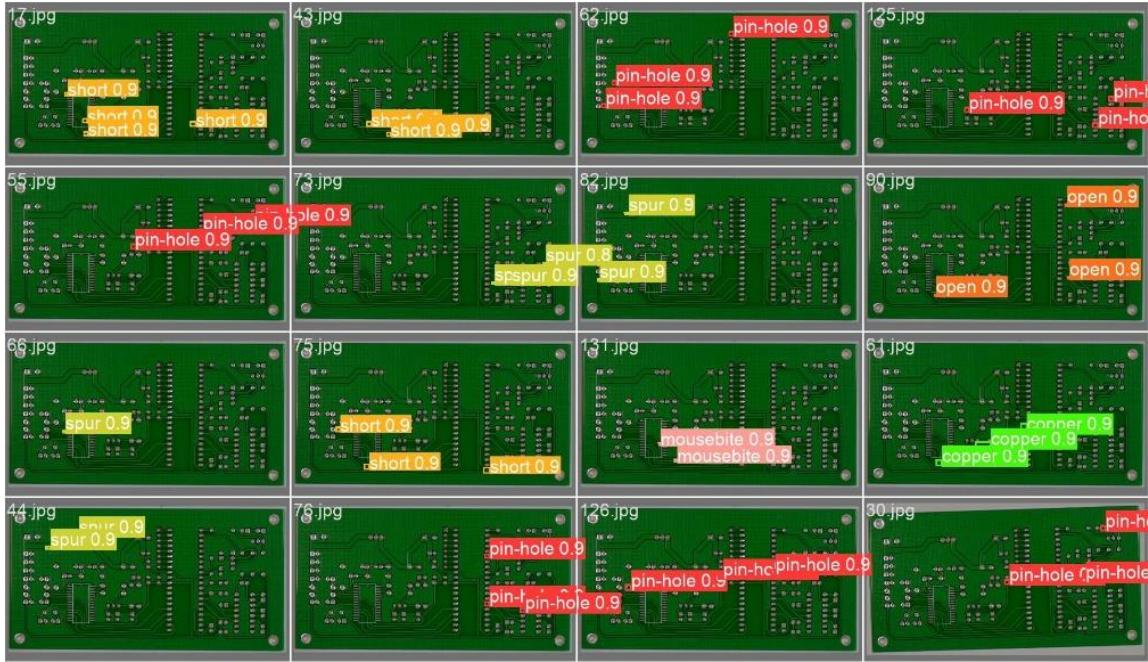


Рис. 2. Обнаружение дефектов печатных плат с помощью модели YOLOv8n OBB на изображениях из набора данных PCB Defect Dataset

внимания (SimAM, CA), а также пирамидальные структуры для объединения признаков на разных масштабах (BiFPN, SPD). Это позволяет моделям эффективно работать с дефектами различных размеров и на сложном фоне. Архитектуры на базе трансформеров (DETR, RT-DETR) начинают превосходить классические CNN по точности и скорости в задачах детекции дефектов, особенно при необходимости учитывать сложные взаимосвязи между объектами на изображении.

Предложенная модель YOLOv8n, дообученная на специализированных наборах данных, демонстрирует значения mAP50 0,98 и 0,99 на соответствующих тестовых наборах, что сопоставимо или превосходит лучшие мировые результаты.

Библиографические ссылки

1. Венгеренко В. В., Иютин А. В. Гибридный контроль дефектов печатных плат // Информатика. 2024. Т. 21, № 3. С. 63–79.
2. SSD: Single Shot MultiBox Detector / W. Liu [et al.] // Computer Vision – ECCV 2016 : 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings / eds.: B. Leibe [et al.]. Cham : Springer, 2016. Part I. P. 21–37.
3. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon [et al.] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 779–788.
4. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks / S. Ren [et al.] // Advances in Neural Information Processing Systems 28 : 29th Annual Conference on Neural Information Processing Systems 2015, Montreal, Canada,

7–12 December 2015 / eds.: C. Cortes [et al.]. Red Hook, NY : Curran Associates, 2016. Vol. 1. P. 91–99.

5. Attentive context and semantic enhancement mechanism for printed circuit board defect detection with two-stage and multi-stage object detectors / T. Kioby [et al.] // Scientific Reports. 2024. Vol. 14. Article no. 18124.

6. U2D2PCB: Uncertainty-Aware Unsupervised Defect Detection on PCB Images Using Reconstructive and Discriminative Models / C. Chen [et al.] // IEEE Transactions on Instrumentation and Measurement. 2024. Vol. 73. P. 1–10.

7. Online PCB Defect Detector On A New PCB Defect Dataset / S. Tang [et al.] // arXiv preprint arXiv:1902.06197. 2019.

8. DOTA. A Large-Scale Benchmark and Challenges for Object Detection in Aerial Images. URL: <https://captain-whu.github.io/DOTA/index.html> (date of access: 02.05.2025).

9. OpenCV: Introduction to SIFT (Scale-Invariant Feature Transform). URL: https://docs.opencv.org/4.x/da/df5/tutorial_py_sift_intro.html (date of access: 05.05.2025).

10. OpenCV: Feature Matching. URL: https://docs.opencv.org/4.x/dc/dc3/tutorial_py_matcher.html (date of access: 05.05.2025).

11. OpenCV: Geometric Image Transformations. URL: https://docs.opencv.org/4.x/da/d54/group__imgproc__transform.html (date of access: 07.05.2025).

12. YOLO-BFRV: An Efficient Model for Detecting Printed Circuit Board Defects / J. Liu [et al.] // Sensors. 2024. Vol. 24, iss. 18. Article no. 6055.

13. Global contextual attention augmented YOLO with ConvMixer prediction heads for PCB surface defect detection / K. Xia [et al.] // Scientific Reports. 2023. Vol. 13, iss. 1. Article no. 9805.

14. Lightweight PCB defect detection method based on SCF-YOLO / Y. Li [et al.] // PLOS ONE. 2025. Vol. 20, iss. 4. DOI: [10.1371/journal.pone.0318033](https://doi.org/10.1371/journal.pone.0318033).

15. Xiao G., Hou S., Zhou H. PCB defect detection algorithm based on CDI-YOLO // Scientific Reports. 2024. Vol. 14, iss. 1. Article no. 7351.

16. Yuan T., Jiao Z., Diao N. YOLO-SSW: An Improved Detection Method for Printed Circuit Board Surface Defects // Mathematics. 2025. Vol. 13, iss. 3. Article no. 435.

17. DETRs Beat YOLOs on Real-time Object Detection / Y. Zhao [et al.] // Proc. of the IEEE/CVF conference on computer vision and pattern recognition. 2024. P. 16965–16974.