



Обнаружение аномалий на печатных платах с помощью β -вариационного автоэнкодера

¹ Т.С. Ходатаева, ORCID: 0000-0002-6284-2292 <tkhodataeva@gmail.com>

^{2,3} Л.Е. Карпов, ORCID: 0000-0001-6400-8325 <mak@ispras.ru>

¹ Марийский государственный университет,
Россия, 424000, г. Йошкар-Ола, площадь им. В.И. Ленина, д. 1.

² Институт системного программирования им. В.П. Иванникова РАН (ИСП РАН),
Россия, 109004, г. Москва, ул. А. Солженицына, д. 25.

³ Московский государственный университет имени М.В. Ломоносова,
119991, Россия, Москва, Ленинские горы, д. 1.

Аннотация. В условиях промышленного производства сбор репрезентативных данных о дефектах печатных плат затруднён, что делает методы контролируемого обучения малоприменимыми. В данной работе исследуется альтернативный подход – одноклассовое обнаружение аномалий на основе β -вариационного автоэнкодера (β -VAE), при котором модель обучается исключительно на изображениях бездефектных плат. Основной фокус работы – анализ влияния неоднородности данных на качество детекции. Эксперименты на наборе данных с четырьмя типами печатных плат показали, что обучение отдельной модели для каждого типа платы позволяет достичь высокого качества (ROC-AUC до 0.98). В то же время, попытка создать универсальную модель для всех типов плат приводит к резкому падению эффективности (ROC-AUC < 0.69), что свидетельствует о критическом влиянии вариативности топологии. Визуализация латентного пространства с помощью t-SNE подтверждает, что оптимальный параметр β способствует лучшему разделению нормальных и аномальных образцов. Наибольшую практическую ценность демонстрирует специализированная свёрточная архитектура β -CVAE, показавшая конкурентные результаты при значительно меньших вычислительных затратах по сравнению с современными методами.

Ключевые слова: одноклассовое обучение; обнаружение аномалий; вариационный автоэнкодер (β -VAE); автоматическая оптическая инспекция; печатные платы; глубокое обучение; неоднородность данных.

Для цитирования: Ходатаева Т.С., Карпов Л.Е. Обнаружение аномалий на печатных платах с помощью β -VAE. Труды ИСП РАН, том 37, вып. 6, часть 4, 2025 г., стр. 61–72. DOI: 10.15514/ISPRAS-2025-37(6)-50.

Благодарности: Работа выполнена на базе ФГБОУ ВО Марийского государственного университета в сотрудничестве с ведущим предприятием по производству печатных плат «ТЕХНОТЕХ» в городе Йошкар-Ола.

Anomaly Detection on Printed Circuit Boards using a β -Variational Autoencoder

¹ T.S. Khodataeva ORCID: 0000-0002-6284-2292 <tkhodataeva@gmail.com>

^{2,3} L.E. Karpov, ORCID: 0000-0001-6400-8325 <mak@ispras.ru>

¹ Mari State University, 1, pl. Lenina, Yoshkar-Ola, 424000, Russia.

² Ivannikov Institute for System Programming of the Russian Academy of Sciences, 25, Alexander Solzhenitsyn st., Moscow, 109004, Russia.

³ Lomonosov Moscow State University, GSP-1, Leninskie Gory, Moscow, 119991, Russia.

Abstract. Collecting representative defect data for printed circuit boards is challenging in industrial production, making supervised learning methods less applicable. This work investigates an alternative approach using β -Variational Autoencoder (β -VAE) for one-class anomaly detection, where models are trained exclusively on defect-free board images. The study focuses on analyzing how data heterogeneity affects detection quality. Experiments on a dataset containing four PCB types demonstrated that training separate models for each board type achieves high performance (ROC-AUC up to 0.98). Conversely, attempting to create a universal model for all board types resulted in significant performance degradation (ROC-AUC < 0.69), highlighting the critical impact of topological variability. Latent space visualization using t-SNE confirmed that optimal β parameter values promote better separation between normal and anomalous samples. The specialized convolutional β -CVAE architecture demonstrated the highest practical value, achieving competitive results with significantly lower computational costs compared to state-of-the-art methods.

Keywords: one-class learning; anomaly detection; variational autoencoder (β -VAE); automatic optical inspection; printed circuit boards; deep learning; data heterogeneity.

For citation: Khodataeva T.S., Karpov L.E. Anomaly Detection on Printed Circuit Boards using a β -Variational Autoencoder. *Trudy ISP RAN/Proc. ISP RAS*, vol. 37, issue 6, part 4, 2025, pp. 61-72 (in Russian). DOI: 10.15514/ISPRAS-2025-37(6)-50.

Acknowledgements. This research was conducted at Mari State University in collaboration with "TECHNOTECH" company, a leading printed circuit board manufacturer in Yoshkar-Ola.

1. Введение

Контроль качества токопроводящего рисунка печатных плат (ПП) – критически важная задача в электронной промышленности [1]. Традиционные методы автоматической оптической инспекции (АОИ), основанные на контролируемом обучении [2–7], показывают высокую точность, но требуют репрезентативных наборов данных со всеми возможными типами дефектов. В реальном производстве сбор таких данных затруднён из-за редкости и многообразия аномалий.

Перспективной альтернативой являются методы одноклассового обнаружения аномалий (Anomaly Detection, AD), где модель обучается только на бездефектных образцах [8–13]. В этом подходе дефекты выявляются как отклонения от изученного распределения «нормы». Все многообразие методов AD можно разделить на два основных класса:

- Методы реконструкции на основе автоэнкодеров, вариационных автоэнкодеров VAE (Variational Autoencoder) [14, 15], GAN (Generative Adversarial Network) [16-19], где аномалии обнаруживаются по высокой ошибке восстановления;
- Методы на основе сходства в пространстве признаков такие как PatchCore, PaDiM [20, 21], где аномалии определяются как выбросы в пространстве признаков, извлечённых предобученными свёрточными нейронными сетями.

Несмотря на свою эффективность, методы PatchCore и PaDiM имеют существенные ограничения. Они склонны игнорировать глобальный контекст изображения, что критично

для сложных структур ПП. Кроме того, их недостатки включают сложность интерпретации локализованных признаков, чувствительность к шуму и высокие вычислительные и память-зависимые затраты при моделировании распределения в условиях высокой вариативности данных.




Рис. 1. Принцип обнаружения аномалий через реконструкцию VAE.
Fig.1. Principle of anomaly detection through VAE reconstruction.

Методы реконструкции, в частности вариационные автоэнкодеры [22] (рис. 1), представляют особый интерес благодаря наглядной интерпретации результатов через карты различий. Однако ключевой проблемой, ограничивающей эффективность методов AD в реальной промышленности, является вариативность внутри класса «норма». В контексте инспекции ПП она проявляется на двух уровнях:

- Внутрикласовая вариативность. Различия в текстуре подложки, освещении и плотности трассировки даже для плат одного типа.
- Мультидоменная вариативность. Существенные различия в топологии между разными типами плат, где каждый тип платы фактически представляет собой отдельный домен.

Существующие исследования [23] часто фокусируются на однородных данных, в то время как вопрос устойчивости методов AD к топологической неоднородности изучен недостаточно. В последние годы для повышения устойчивости к этим вариациям активно развиваются сложные методы, однако их применение для инспекции ПП ограничено:

- Нормализующие потоки (Normalizing Flows) [24, 25], которые предлагают точную оценку правдоподобия, но накладывают жесткие архитектурные ограничения (обратимость преобразований, одинаковость размерностей), что приводит к значительным вычислительным затратам для высокоразмерных изображений ПП.
- Техники контрастного обучения (Contrastive Learning) [26, 27], эффективность которых критически зависит от тщательного подбора аугментаций данных, и они сложны для интерпретации в промышленных системах.
- Подходы доменной адаптации (Domain Adaptation) [28, 29], которые, стремясь к инвариантности признаков к домену (типу платы), рискуют утратить чувствительность к самим аномалиям, являющимся локальными отклонениями от специфичной топологии. Кроме того, эти подходы требуют репрезентативных данных из целевых доменов на этапе обучения.

Таким образом, хотя современные SOTA-методы (State-of-the-Art) демонстрируют успехи на общих наборах данных, их прямолинейное применение для инспекции ПП с уникальной топологической спецификой зачастую неприемлемо вследствие высоких вычислительных затрат и сложности настройки.

Основной вклад данной работы заключается в глубоком эмпирическом анализе, который с использованием вычислительно эффективной архитектуры свёрточного β -вариационного автоэнкодера (β -CVAE) количественно демонстрирует критическую важность специализации модели под конкретный домен (тип платы). Мы фокусируемся на доказательстве тезиса о том, что в условиях высокой топологической вариативности переход

от универсальной модели к специализированному решению является не опцией, а обязательным требованием для успешного промышленного внедрения. Наши эксперименты, показавшие катастрофическое падение качества (ROC-AUC < 0.69) универсальной модели, обученной на всех типах плат, являются прямым подтверждением этого тезиса.

Целью данной работы является исследование применимости и ограничений β -CVAE для одноклассового обнаружения аномалий на токопроводящем рисунке ПП. Модель β -CVAE выбрана за счёт способности регулировать баланс между качеством реконструкции и регуляризацией латентного пространства с помощью параметра β , что обеспечивает оптимальное соотношение точности, вычислительных затрат и интерпретируемости для промышленной задачи.

Для достижения цели решаются следующие задачи:

- Разработка модифицированной свёрточной архитектуры β -CVAE;
- Проведение экспериментов на наборе данных с изображениями четырёх типов ПП;
- Комплексная оценка качества с использованием метрик ROC-AUC, Precision@k, F1-score;
- Исследование влияния неоднородности данных на качество детекции и проверка альтернативных архитектур (включая EfficientNetB0) для оценки проблемы избыточной реконструкции.

2. Архитектура сверточного β -вариационного автоэнкодера

Для решения задачи одноклассового обнаружения аномалий (AD) была разработана специализированная архитектура β -CVAE, учитывающая требования конкретного применения и основанная на принципах, описанных в работе [30]. Архитектура реализует вероятностный подход к кодированию данных, где энкодер обучается отображать входные изображения в распределение в латентном пространстве, а декодер – восстанавливать изображения из сэмплов этого распределения.

Модель β -CVAE (рис. 2) состоит из трёх основных компонентов: энкодера, слоя репараметризации и декодера:

- Энкодер $q_\phi(z|x)$ преобразует входное изображение x в параметры латентного распределения – вектор средних μ и логарифмов дисперсий $\log \sigma^2$;
- Слой репараметризации генерирует латентный вектор $z = \mu + \sigma \epsilon$, где $\epsilon \sim N(0, I)$, что позволяет применять градиентный спуск, реализует reparameterization trick [14];
- Декодер $p_\theta(x|z)$ восстанавливает изображение из латентного вектора z .

Модель (см. табл. 1) спроектирована для обработки входных изображений ПП размером $256 \times 256 \times 3$ мм (высота \times ширина \times каналы) и использует симметричную свёрточную структуру с четырьмя уровнями уменьшения/увеличения пространственной размерности. Для предотвращения переобучения и повышения стабильности обучения в архитектуре используются пакетная нормализация (*Batch Normalization*) и L2-регуляризация ($\lambda = 1 \times 10^{-4}$) на весах свёрточных ядер.

Энкодер $q_\phi(z|x)$ состоит из четырёх последовательных свёрточных блоков, каждый из которых включает слой *Conv2D* с ядром 4×4 и шагом $stride = 2$, пакетную нормализацию и функцию активации *LeakyReLU* ($\alpha=0.2$). Четырёхкратное уменьшение размерности приводит к размеру пространственных признаков 16×16 . После сглаживания (*Flatten*) полученный вектор подается на два отдельных полносвязных слоя (*Dense*), формирующих параметры распределения латентного пространства μ и $\log \sigma^2$ размерности $D = latent_dim(256)$.

Декодер $p_\theta(x|z)$ восстанавливает изображение x' из латентного вектора z . Он начинается с полносвязного слоя, который восстанавливает вектор до размерности $16 \times 16 \times 256$, после чего применяется слой восстановления формы (*Reshape*). Последующие четыре блока

используют транспонированные свёртки $Conv2DTranspose$ с ядром 4×4 и шагом $stride = 2$ для восстановления пространственной размерности. Финальный слой $Conv2DTranspose$ использует функцию активации $Sigmoid$ для ограничения выходных пиксельных значений в диапазоне $[0, 1]$.

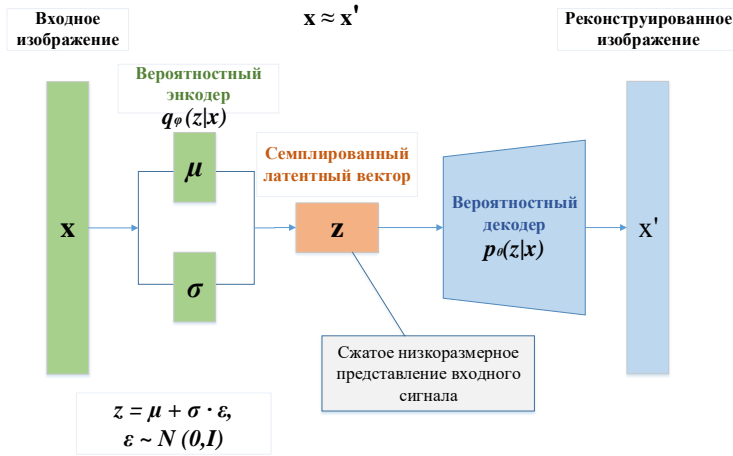


Рис. 2. Архитектура сверточного β -вариационного автоэнкодера.
Fig. 2. Architecture of convolutional β -variational autoencoder.

Табл. 1. Архитектура сверточного β -CVAE ($latent_dim = 256$).
Table 1. Architecture of the Convolutional β -CVAE ($latent_dim = 256$).

Компонент	Слой	Параметры (Ядро, Шаг)	Выходная размерность (H, W, C)
Энкодер	Input		(256, 256, 3)
	$Conv2D \rightarrow BN \rightarrow LeakyReLU$	(4, 4), stride 2	(128, 128, 32)
	$Conv2D \rightarrow BN \rightarrow LeakyReLU$	(4, 4), stride 2	(64, 64, 64)
	$Conv2D \rightarrow BN \rightarrow LeakyReLU$	(4, 4), stride 2	(32, 32, 128)
	$Conv2D \rightarrow BN \rightarrow LeakyReLU$	(4, 4), stride 2	(16, 16, 256)
	Flatten		(65536)
	Dense (μ и $\log \sigma^2$)		$latent_dim(256)$
Репараметризация	Sampling		(256)
Декодер	Dense		(65536)
	Reshape		(16, 16, 256)
	$Conv2DTranspose \rightarrow BN \rightarrow LeakyReLU$	(4, 4), stride 2	(32, 32, 128)
	$Conv2DTranspose \rightarrow BN \rightarrow LeakyReLU$	(4, 4), stride 2	(64, 64, 64)
	$Conv2DTranspose \rightarrow BN \rightarrow LeakyReLU$	(4, 4), stride 2	(128, 128, 32)
	$Conv2DTranspose \rightarrow BN \rightarrow LeakyReLU$	(4, 4), stride 2	(256, 256, 32)
	$Conv2DTranspose (Sigmoid)$	(4, 4), stride 1	(256, 256, 3)

Функция потерь – модифицированный метод определения нижней вариационной границы правдоподобия ELBO (Evidence Lower Bound) с параметром β , регулирующим баланс между ошибкой реконструкции и регуляризацией латентного пространства [30].

Обучение β -CVAE направлено на максимизацию оценки правдоподобия ELBO:

$$L(\theta, \varphi; x) = E_{\{q_{\varphi}(z|x)\}}[\log p_{\theta}(x|z)] - \beta * D_{KL}(q_{\varphi}(z|x) || p(z)) \quad (1)$$

где:

- $E_{\{q_{\varphi}(z|x)\}}[\log p_{\theta}(x|z)]$ – слагаемое реконструкции (например, MSE), отвечающее за качество восстановления входного изображения;

- $D_{KL}(q_{\varphi}(z|x) || p(z))$ – KL-дивергенция, выступающая в роли регуляризатора. Она притягивает апостериорное распределение $q_{\varphi}(z|x)$ к априорному $p(z) = N(0, I)$;
- β – гиперпараметр, управляющий балансом между двумя слагаемыми.

Роль параметра β :

- $\beta = 1$: соответствует стандартному VAE;
- $\beta > 1$: усиливает влияние регуляризатора. Это приводит к более компактному и дисинтегрированному (разделимому) латентному пространству, но может ухудшить качество реконструкции;
- $\beta < 1$: ослабляет регуляризацию, уделяя больше внимания точности реконструкции. Это может помочь в восстановлении сложных деталей, но рискует переобучиться на шум и аномалии.

Оптимальное значение β подбиралось экспериментально для каждого типа платы (см. табл. 3), чтобы найти компромисс между способностью модели к обобщению признаков "нормы" и чувствительностью к аномальным отклонениям.

Метрики оценки:

- Для комплексной оценки использовались: ROC-AUC (устойчивость к выбору порога) [31, 32], Precision@k (качество топ-k предсказаний, критично для оператора) [33] и F1-score (баланс между точностью и полнотой) [34].
- Для визуализации структуры латентного пространства применялся алгоритм t-SNE [35].

3. Эксперименты и результаты

3.1 Экспериментальная установка и данные

Эксперименты проводились на платах GPU NVIDIA GeForce RTX 4090 с использованием TensorFlow/Keras. Набор данных содержал изображения четырех типов ПП (табл. 2), полученные с промышленной камеры [36]. Подготовка данных включала разбиение на перекрывающиеся фрагменты 512×512, масштабирование до 256×256 и аугментацию (отражения) только для класса "норма".

Табл. 2. Объем данных в наборе данных по каждому типу плат.

Table 2. Data volume in the dataset by each board type.

Тип платы	Класс "Норма"	Класс "Аномалия"	Общий объем
Плата 1	2 160	148	2 308
Плата 2	749	160	909
Плата 3	3 392	328	3 720
Плата 4	8 464	216	8 680
Всего	14 765	852	15 617

3.2 Результаты работы специализированного энкодера β -CVAE

Модель продемонстрировала высокое качество детекции при обучении отдельно для каждого типа платы (табл. 3). Наилучший результат достигнут для Платы 4 (ROC-AUC = 0.98), что свидетельствует об эффективности подхода для задач с выраженной "нормой". Визуальный анализ (рис. 3) подтвердил способность модели корректно реконструировать нормальные области и исказить аномальные.

3.3 Метрики качества

Качественный анализ подтверждает количественные результаты. Модель после 150 эпох обучения эффективно реконструирует нормальные области, но создает артефакты в местах дефектов, что визуализирует механизм обнаружения аномалий (рис. 4).

Табл. 3. Метрики качества обнаружения аномалий для каждого типа платы.

Table 3. Anomaly Detection Quality Metrics for Each Board Type.

Тип платы	β	ROC-AUC	Precision@k	F1-score
Плата 1	0.3	0.9271	0.5135	0.8043
Плата 2	0.5	0.9516	0.8375	0.8776
Плата 3	0.3	0.9460	0.8628	0.9314
Плата 4	0.5	0.9800	0.9800	0.9800




Рис. 3. Визуализация латентного пространства методом t -SNE для платы типа 4.

Fig. 3. Latent space visualization using t -SNE method for board type 4.

- ROC-AUC: интегральная оценка разделительной способности модели;
- Precision@k: точность среди k наиболее аномальных предсказаний (важно для оператора);
- F1-score: сбалансированная оценка точности и полноты.

Этот вывод дополнительно подтверждается анализом латентного пространства с помощью t -SNE: для Платы 4 с оптимальным значением параметра β аномальные образцы (красные точки на рис. 3) формируют отдельные кластеры на периферии плотного облака нормальных данных (зеленые точки на рис. 3), что соответствует принципу одноклассового обучения.

3.4 Эксперимент на объединенном наборе данных

Обучение единой модели на данных всех типов плат привело к резкому падению качества: ROC-AUC = 0.6891, Precision@k = 0.0833. Это прямо указывает на неспособность базовой архитектуры β -CVAE обобщать признаки для сильно различающихся топологий.

3.5 Сравнение с современными методами и анализ архитектурных решений

В рамках данного исследования был предпринят глубокий анализ архитектурных решений, направленный на оптимизацию эффективности β -CVAE для специфики задачи инспекции ПП. Основное внимание было уделено исследованию модифицированной архитектуры с интегрированным предобученным энкодером EfficientNet-B0 – архитектурой, лежащей в основе современного метода EfficientAd [37]. Для оценки конкурентоспособности финального решения также было проведено сравнение с методом PatchCore.




Рис. 4. Реконструкция изображений с дефектами (Платы типа 1, 2, 3, 4).
Fig. 4. Reconstruction of images with defects (Board types 1, 2, 3, 4).

С целью повышения выразительности латентного пространства была исследована модифицированная архитектура β -CVAE, в которой энкодер заменен на предобученную EfficientNet-B0, оптимальную для работы с изображениями разрешения 256×256 . При этом декодер остался прежним, состоящим из 5 последовательных сверточных блоков, что создало потенциальный дисбаланс емкости между мощным энкодером и простым декодером.

Эксперименты подтвердили наличие данного дисбаланса:

- При полностью замороженном энкодере EfficientNet-B0 модель не могла адаптировать свои признаки к специфике изображений ПП и не обучалась корректной реконструкции.
- Стратегия поэтапного размораживания слоев EfficientNet-B0 (10%, 20%, 30% и далее) в зависимости от номера эпохи обучения не решила проблему: модель по-прежнему не могла сформировать достаточно контрастную карту ошибки для детекции аномалий.
- Введение пропускных соединений (skip-connections) между энкодером и декодером позволило резко улучшить качество реконструкции, но привело к нежелательному эффекту: модель научилась столь точно воспроизводить входные данные, включая области с дефектами, что полностью нивелировало основной механизм обнаружения аномалий, основанный на ошибке реконструкции.

Данный результат указывает на фундаментальную проблему использования избыточно мощных и идеально скоординированных энкодеров и декодеров в контексте AD: их способность к идеальной реконструкции делает их "слепыми" к аномалиям.

На этом фоне особенно показательно сравнение с методом PatchCore, который показал схожую с нашей базовой моделью β -CVAE точность ($\text{ROC-AUC} \approx 0.949$). Однако время обучения PatchCore для 2160 изображений превысило 28 часов, что делает его малоприменимым в условиях динамичного промышленного производства, требующего быстрого развертывания моделей.

Проведенный анализ архитектур демонстрирует, что для успешного решения задачи одноклассового AD в условиях ограниченных вычислительных ресурсов и высокой вариативности данных ключевым является не максимальная мощность модели, а ее сбалансированность и соответствие специфике данных. Предложенный изначально специализированный энкодер β -CVAE, несмотря на меньшую архитектурную сложность, обеспечил оптимальный баланс между точностью, скоростью обучения (~5 минут) и интерпретируемостью результатов, что подтверждает его высокий потенциал для промышленного внедрения.

Заключение

В работе исследована применимость β -CVAE для одноклассового обнаружения аномалий на печатных платах. Эксперименты подтвердили высокую эффективность подхода при обучении на данных одного типа платы (ROC-AUC до 0.98). Ключевым ограничением является чувствительность к неоднородности данных: объединённое обучение на нескольких типах плат приводит к катастрофическому падению качества ($\text{ROC-AUC} < 0.69$).

Попытки улучшения обобщающей способности за счёт интеграции предобученного энкодера EfficientNetB0 и skip-connections, хотя и улучшили реконструкцию, выявили фундаментальную проблему: модель научилась столь точно восстанавливать входные данные, включая дефекты, что нивелировало основной механизм обнаружения аномалий.

Предложенный специализированный β -CVAE демонстрирует оптимальное соотношение точности и вычислительной эффективности для промышленного внедрения по сравнению с SOTA-методами, такими как PatchCore, которые требуют значительных вычислительных ресурсов для больших объемов данных.

Основные выводы:

- Специфичность данных. Для достижения высокой точности необходима специализация модели под конкретную топологию платы;
- Практическая эффективность. Предложенный специализированный энкодер β -CVAE демонстрирует оптимальное соотношение точности и вычислительной эффективности для промышленного внедрения по сравнению с SOTA-методами;
- Проблема избыточной реконструкции. Использование глубоких предобученных энкодеров требует разработки специальных механизмов для подавления восстановления аномалий.

Направления будущих исследований включают внедрение механизмов внимания [38] для игнорирования аномалий при реконструкции, исследование альтернативных архитектур (трансформеры) и разработку адаптивных схем регуляризации латентного пространства.

Список литературы / References

- [1]. Ebayyeh, A., et al. A Review and Analysis of Automatic Optical Inspection and Quality Monitoring Methods in Electronics Industry //IEEE Access. 2020. Vol. 8. P. 183192-183271. DOI: 10.1109/ACCESS.2020.3029127.

- [2]. Adibhatla, V. A., et al. Defect Detection in Printed Circuit Boards Using You-Only-Look-Once Convolutional Neural Networks // *Electronics*. 2020. Vol. 9, No. 9. Art. No. 1547. DOI: 10.3390/electronics9091547.
- [3]. Raihan, F. and Ce, W. PCB defect detection using opencv with image subtraction method // *International Conference on Information Management and Technology (ICIMTech)*. 2017. P. 204-209. DOI: 10.1109/ICIMTech.2017.8273538.
- [4]. Liao, X., et al. Yolov4-mn3 for pcb surface defect detection // *Applied Sciences*. 2021. Vol. 11, No. 24. P. 11701. DOI: 10.3390/app112411701.
- [5]. Du, B., et al. YOLO-MBBi: PCB Surface Defect Detection Method Based on Enhanced YOLOv5 // *Electronics*. 2023. Vol. 12, No. 13. P. 2821. DOI: 10.3390/electronics12132821.
- [6]. Jiang, Y., et al. Lightweight Network DCR-YOLO for Surface Defect Detection on Printed Circuit Boards // *Sensors*. 2023. Vol. 23, No. 17. P. 7310. DOI: 10.3390/s23177310.
- [7]. Pan, Y., et al. Rapid Detection of PCB Defects Based on YOLOx-Plus and FPGA // *IEEE Access*. 2024. Vol. 12. P. 61343-61358. DOI: 10.1109/ACCESS.2024.3387947.
- [8]. Bergmann, P., et al. MVTec AD – A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019. P. 9584-9592. DOI: 10.1109/CVPR.2019.00982.
- [9]. Cohen, N., et al. Sub-Image Anomaly Detection with Deep Pyramid Correspondences. [Электронный ресурс] // *arXiv preprint*. 2020. URL: <https://arxiv.org/abs/2005.02357> (дата обращения: 15.09.2025).
- [10]. Shi, W., et al. Adversarial Semi-Supervised Learning Method for Printed Circuit Board Unknown Defect Detection // *The Journal of Engineering*. 2020. Vol. 2020, No. 13. P. 505–510. DOI: 10.1049/joe.2020.0085.
- [11]. Kim, J., et al. Printed Circuit Board Defect Detection Using Deep Learning via A Skip-Connected Convolutional Autoencoder // *Sensors*. 2021. Vol. 21, No. 15. Art. No. 4968. DOI: 10.3390/s21154968.
- [12]. Adibhatla, V. A., et al. Unsupervised Anomaly Detection in Printed Circuit Boards through Student-Teacher Feature Pyramid Matching // *Electronics*. 2021. Vol. 10, No. 24. Art. No. 3177. DOI: 10.3390/electronics10243177.
- [13]. Ulger, F., et al. Anomaly Detection for Solder Joints Using β -VAE // *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2021. Vol. 11, No. 5. P. 800–810.
- [14]. Kingma, D. P., et al. Auto-Encoding Variational Bayes [Электронный ресурс] // *arXiv preprint*. 2013. URL: <https://arxiv.org/abs/1312.6114> (дата обращения: 15.09.2025).
- [15]. Blei D. M., et al. Variational Inference: A Review for Statisticians // *Journal of the American Statistical Association*. 2017. Vol. 112. No. 518. P. 859-877. DOI: 10.1080/01621459.2017.1285773.
- [16]. Wang, G., et al. Student-Teacher Feature Pyramid Matching for Unsupervised Anomaly Detection [Электронный ресурс] // *arXiv preprint*. 2021. URL: <https://arxiv.org/abs/2103.04257> (дата обращения: 15.08.2025).
- [17]. Venkataramanan, S., et al. Attention guided anomaly localization in images // *Proceedings of the European Conference on Computer Vision*. 2020. P. 485–503.
- [18]. Sato, K., et al. Predictable uncertainty-aware unsupervised deep anomaly segmentation // *International Joint Conference on Neural Networks*. 2019. P. 1–7.
- [19]. Akcay, S., et al. Ganomaly: Semi-supervised anomaly detection via adversarial training // *Proceedings of the Asian Conference on Computer Vision*. 2018. P. 622–637.
- [20]. Roth, K., et al. Towards Total Recall in Industrial Anomaly Detection // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022. P. 14318–14328. DOI: 10.1109/CVPR52688.2022.01394.
- [21]. Defard, T., et al. Padim: A Patch Distribution Modeling Framework for Anomaly Detection and Localization // *Pattern Recognition and Computer Vision (PRCV)*. 2021. *Lecture Notes in Computer Science*, vol. 13020. P. 475–489. DOI: 10.1007/978-3-030-88007-1_36.
- [22]. Doersch, C. Tutorial on variational autoencoders [Электронный ресурс] // *arXiv preprint*. 2016. URL: <https://arxiv.org/abs/1606.05908> (дата обращения: 15.08.2025).
- [23]. Bergmann, P., et al. The MVTec Anomaly Detection Dataset: A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection // *International Journal of Computer Vision*. 2021. Vol. 129. P. 1038–1059. DOI: 10.1007/s11263-020-01400-4.
- [24]. Yu, J., et al. FastFlow: Unsupervised Anomaly Detection and Localization via 2D Normalizing Flows [Электронный ресурс] // *arXiv preprint*. 2021. URL: <https://arxiv.org/abs/2111.07677> (дата обращения: 17.10.2025).

- [25]. Chiu, L., et al. Self-Supervised Normalizing Flows for Image Anomaly Detection and Localization. // IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. 2023. P. 2927-2936, DOI: 10.1109/CVPRW59228.2023.00294.
- [26]. Liao, L., et al. GCAFlow: Multi-Scale Flow-Based Model with Global Context-Aware Channel Attention for Industrial Anomaly Detection // *Sensors*. 2025. Vol. 25, P. 3205. DOI:10.3390/s25103205.
- [27]. Yin, S., et al. Contrastive Learning with Global and Local Representation for Mixed-Type Wafer Defect Recognition // *Sensors*. 2025. Vol. 25, No. 4. P. 1272. DOI:10.3390/s25041272.
- [28]. Hua, L., et al. MedicalCLIP: Anomaly-Detection Domain Generalization with Asymmetric Constraints. *Biomolecules*. 2024. Vol. 14, No. 5. P. 590. DOI: 10.3390/biom14050590. PMID: 38785997; PMCID: PMC11117918.
- [29]. Heo, J., et al. Multi-class Image Anomaly Detection for Practical Applications: Requirements and Robust Solutions [Электронный ресурс] // arXiv preprint. 2025. URL: <https://arxiv.org/abs/2508.02477> (дата обращения: 15.09.2025).
- [30]. Higgins, I., et al. beta-VAE: Learning Basic Visual Concepts with a Constrained Variational Framework // *Proceedings of the 5th International Conference on Learning Representations*. 2017.
- [31]. Fawcett, T. An Introduction to ROC Analysis // *Pattern Recognition Letters*. 2006. Vol. 27, No. 8. P. 861–874. DOI: 10.1016/j.patrec.2005.10.010.
- [32]. Bradley, A. P. The use of the area under the ROC curve in the evaluation of machine learning algorithms // *Pattern Recognition*. 1997. Vol. 30, No. 7. P. 1145–1159.
- [33]. Liu, T. Y. Learning to Rank for Information Retrieval // *Foundations and Trends in Information Retrieval*. 2009. Vol. 3, No. 3. P. 225–331. DOI: 10.1561/15000000016.
- [34]. Saito, T., et al. The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets // *PLOS ONE*. 2015. Vol. 10, No. 3. P. e0118432. DOI: 10.1371/journal.pone.0118432.
- [35]. Van der Maaten, L. J. P. et al. Visualizing High-Dimensional Data Using t-SNE // *Journal of Machine Learning Research*. 2008. Vol. 9. P. 2579-2605.
- [36]. Khodataeva T. S. Automation of visual inspection of printed circuit boards // *Proceedings of the 34th International Conference GraphiCon'2024*. Omsk. 2024. P. 451–465. DOI: 10.25206/978-5-8149-3873-2-2024-451-465.
- [37]. Zhang J., et al. EfficientAd: Accurate Visual Anomaly Detection at Millisecond-Level Latencies // *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. 2023. P. 128-138.
- [38]. Vaswani, A., et al. Attention is All You Need [Электронный ресурс] // arXiv preprint. 2017. URL: <https://arxiv.org/abs/1706.03762> (дата обращения: 15.09.2025).

Информация об авторах / Information about authors

Татьяна Сергеевна ХОДАТАЕВА – программист научно-исследовательской лаборатории разработки, проектирования и технической инспекции печатных плат. Сфера научных интересов: распознавание образов, глубокое обучение, нейронные сети.

Tatiana Sergeevna KHODATAEVA is a programmer of the research laboratory for the development, design and technical inspection of printed circuit boards. Research interests: pattern recognition, deep learning, neural networks.

Леонид Евгеньевич КАРПОВ – доктор технических наук, главный научный сотрудник ИСП РАН, доцент кафедры системного программирования факультета ВМК. Научные интересы: системное программирование, методы компиляции, системы программирования, нейронные сети.

Leonid Evgenievich KARPOV – Dr. Sci. (Tech.), leading researcher at ISP RAS, associate Professor of the System Programming Department of the VMK Faculty. Research interests: system programming, compilation techniques, programming systems, neuron networks.

