

Р. М. Новиков^{1✉}, Д. Н. Титов¹

Сравнение эффективности алгоритмов нейросетевого анализа дефектов с применением оптической системы в контроле качества поверхности патронов

¹Сибирский государственный университет геосистем и технологий,
г. Новосибирск, Российская Федерация
e-mail: romanov7@live.ru¹

Аннотация. Статья посвящена разработке подхода к автоматическому обнаружению дефектов на корпусах гильз с помощью сверточного автокодировщика (CAE). Актуальность задачи определяется необходимостью оперативного и точного контроля качества в современных условиях промышленной автоматизации: выявления царапин, вмятин и микротрещин. В статье описана архитектура CAE, адаптированная под ограниченный объём обучающих данных, и проведён анализ влияния параметров съёмки (разрешения, фокусного расстояния), конфигурации освещения и нормировки яркости на качество детекции. Эксперименты выполнены в двух режимах: статическом (обработка заранее подготовленных изображений) и динамическом (в реальном времени). Проведённый анализ позволил выявить слабые стороны модели, намечены пути дальнейшей доработки.

Ключевые слова: Искусственный интеллект, сверточные нейронные сети, машинное зрение, глубокое обучение, повышение качества

R. M. Novikov^{1✉}, D. N. Titov¹

Comparison of Efficiency of algorithms of neural network analysis of defects with the use of optical system in controlling the quality of the surface of cartridge casings

¹Siberian State University of Geosystems and Technologies, Novosibirsk, Russian Federation
e-mail: romanov7@live.ru¹

Abstract. The paper presents an approach for automatic defect detection on cartridge casings using a convolutional autoencoder (CAE). The need for timely and accurate quality control in modern industrial automation—specifically the identification of scratches, dents, and microcracks - drives the relevance of this work. We describe a CAE architecture adapted to a limited training dataset and analyze the impact of imaging parameters (resolution, focal length), lightening configuration, and brightness normalization on detection performance. Experiments were conducted in two modes: static (processing of pre-acquired images) and dynamic (in real-time). The analysis revealed weaknesses in the current model that must be addressed in future refinements.

Keywords: Artificial intelligence, convolutional neural networks, machine vision, deep learning, quality improvement

Введение

В условиях современной промышленной автоматизации обнаружение дефектов на поверхностях металлических изделий приобретает все большую актуальность. В частности, контроль качества патронов (гильз) требует высокой точ-

ности и скорости обработки изображений, чтобы вовремя выявлять царапины, вмятины и микротрещины. В этой статье рассматривается применение сверточного автокодировщика (Convolutional Autoencoders, CAE) для задачи аномальной детекции на корпусах гильз [1], проводится анализ влияния параметров съёмки, освещения и нормировки яркости. Рассматриваются встречающиеся в процессе обработки проблемы применения сверточных автокодировщиков в условиях малого количества входных данных [2].

Методы и методики исследования

Модель сверточного автокодировщика будет обучаться в условиях малого количества данных, 48 фотографий «чистых» гильз без дефектов, на их основе выявлять аномалии на новых кадрах [3]. Эффективность метода будет оцениваться как на заранее подготовленном наборе изображений (далее – статический метод), так и в реальном времени при захвате видеопотока с камеры (далее – динамический метод).

Блок-схема используемой установки для контроля качества гильз изображена на рис. 1.

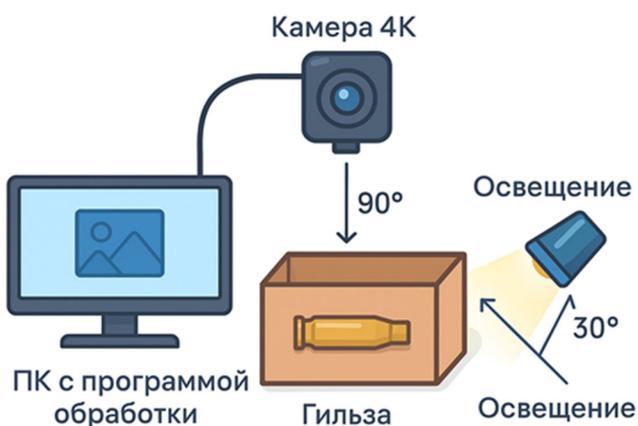


Рис. 1. Блок-схема установки для контроля качества гильз

Сенсор и оптика главной камеры:

- матричный сенсор 64 МП, размер 1/2,0";
- эффективный размер пикселя: 0,7 μm (одиночный) \rightarrow 1,4 μm (4-в-1 агрегирование);
- диафрагма $f/1,79$ ($\approx f/1,8$), фазовый автофокус (PDAF);
- выдержка 1/125 s;
- ISO 50;
- цветовая температура светодиодного кольца 4996 K;
- видео возможности 4K (3840 \times 2160) 30 кадров/с;
- угол наклона камеры фиксируется вертикально 0°.

Возможные конфигурации освещения приведены в табл. 1.

Влияние угла падения освещения на визуализацию дефектов поверхности

Угол падения света (от нормали)	Описание конфигурации освещения	Влияние на видимость дефектов
0°	Освещение вертикальное	Выявляются крупные дефекты: глубокие царапины, сколы. Характерно наличие пересвеченных областей.
30–45°	Освещение под углом сверху	Хорошо визуализируются крупные дефекты: царапины, сколы. Уровень засветов умеренный.
90°	Освещение в горизонтальной плоскости	Подчёркиваются мелкие дефекты: пыль, микрочастицы, мелкие царапины. Засветы практически отсутствуют.

Освещение влияет на яркость и контрастность изображения, а так же на наличие бликов, поэтому оно должно быть статичным [4]. В дальнейшем в работе используем вертикальное освещение под углом 30°.

Алгоритм 1. Статическая детекция

Разработанная архитектура автоэнкодера предназначена для обработки наборов изображений, приведенных к квадратной форме. Архитектура обучения сети приведена в схеме на рис. 2 [5].

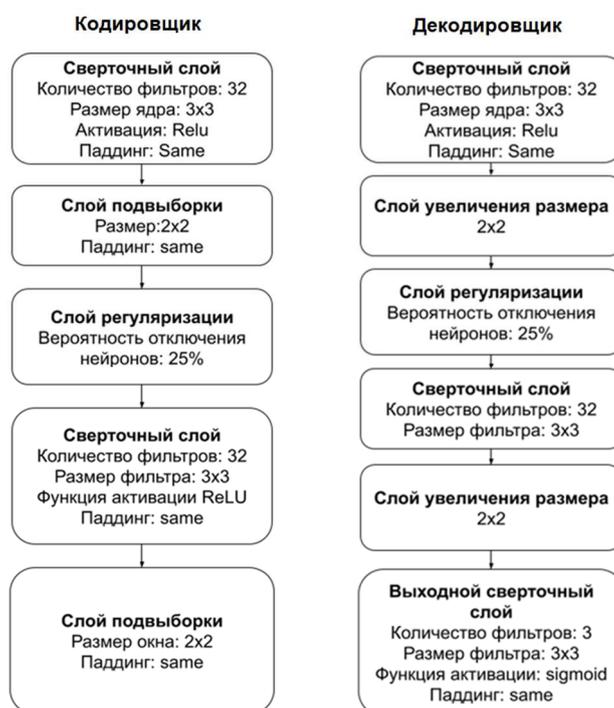


Рис. 2. Архитектура автоэнкодера

Результатом работы одного полного цикла является восстановленное изображение с размерами $960 \times 960 \times 3$.

Алгоритм системы: полный кадр $3840 \times 2160 \rightarrow$ обрезка области интереса (ROI) $1552 \times 450 \rightarrow$ нормализация \rightarrow вывод результата \rightarrow расчёт ошибки реконструкции \rightarrow сравнение с порогом \rightarrow при превышении порога — фиксация дефекта.

При изменении размеров в квадратную форму фактически искажается область корпуса гильзы, повышая относительную плотность пикселей на дефектах. В то же время алгоритмы изменения размера влияют на цвет, монотонность, линейность и структурную целостность данных, особенно при переходе между нестандартными (например, 1552×448) и квадратными (960×960) форматами [6].

При уменьшении изображения с 1552×448 до 960×960 при бикубическом методе наблюдается стандартное отклонение цветовых каналов на 12–18%, что свидетельствует о потере цветового разнообразия. Это приводит к потере деталей, появляются артефакты цветопередачи, различия в освещении между кадрами усложняют задачи машинного обучения и компьютерного зрения.

Нормализация яркости решает эти проблемы путём:

- приведения гистограммы яркости к заданному диапазону;
- коррекции экспозиции для сохранения деталей в тенях и светах;
- устранения шумов, связанных с неравномерным освещением.

Схема используемого алгоритма нормализации показана на рис. 3 [7].



Рис. 3. – Схема нормализации

На рис. 4 представлен результат работы алгоритма нормализации, где яркость одного снимка искусственно занижена.

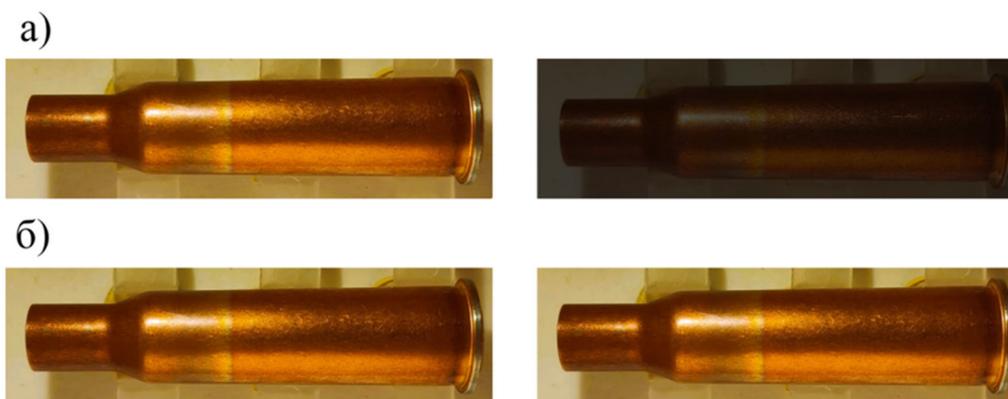


Рис. 4. а) до нормализации, б) после нормализации

Финальные результаты реконструкции, а также примеры первых четырёх патронов из выборки приведены на рис. 5. В верхнем ряду отображены исходные изображения, в нижнем – соответствующие им реконструкции, полученные моделью [8].



Рис. 5. Демонстрация реконструкции автоэнкодера

Ниже приведены значения ошибки реконструкции для каждого изображения:

Image 1: No Defect (Reconstruction Error: 0.0528) – Изображение 1: Без дефекта (Реконструированная ошибка: 0.0528)

Image 2: No Defect (Reconstruction Error: 0.0540) – Изображение 2: Без дефекта (Реконструированная ошибка: 0.0540)

Image 3: Defect (Reconstruction Error: 0.0733) – Изображение 3: С дефектом (Реконструированная ошибка: 0.0733)

Image 4: Defect (Reconstruction Error: 0.0747) – Изображение 4: С дефектом (Реконструированная ошибка: 0.0747)

Алгоритм 2. Динамическая детекция с камеры

При обучении алгоритма динамической детекции использовалась та же модель автоэнкодера, ориентированная на обработку видеок кадров в реальном времени. При съёмке в реальном времени необходимо отключать автоматический подбор яркости, автофокусировку и автоматическую контрастность используемой камеры. Для динамики нужно чётко выбирать разрешение, так как обработка происходит в реальном времени. Операции сжатия изображения уменьшают время на пост-обработку, но нужно, чтобы это уменьшение было эффективнее, чем время на совершение операций сжатия [9].

Для уменьшения влияния положения патрона в кадре на результаты работы модели использовалась аугментация данных, в частности параметр `rotation_range=20`, который задаёт случайные повороты изображения в пределах 20 градусов. Это позволило модели обучаться на изображениях с различными ориентациями объекта, делая её инвариантной к небольшим поворотам. Дополнительно, параметры сдвига (`width_shift_range` и `height_shift_range`) и отражения (`horizontal_flip`) способствовали снижению зависимости от фиксированного положения патрона, что улучшило обобщающую способность модели.

Для дополнительной обработки изображений могут применяться спектральные фильтры, позволяющие выделять контуры объектов и выявлять области засветов. Выделение контуров может быть особенно полезным при работе на конвейере, например, для разделения патронов между собой.

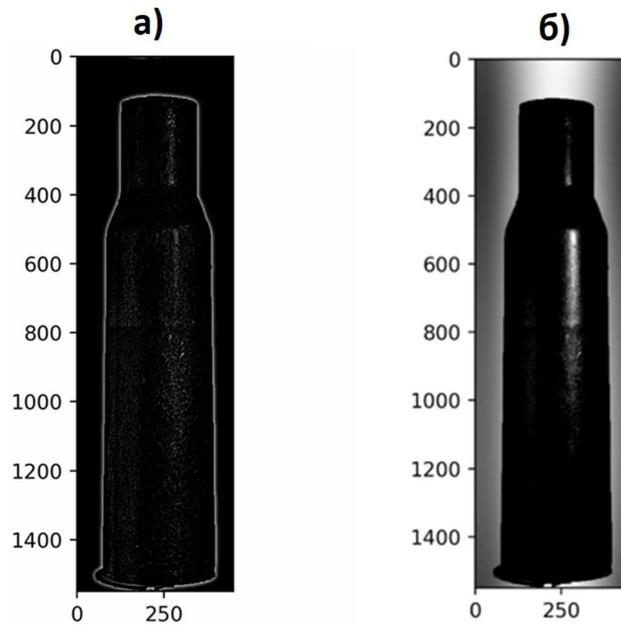


Рис. 6. а) фильтр нижних частот, б) фильтр верхних частот

Демонстрация работы алгоритма реконструкции с использованием данных с камеры представлена на рис. 7. В верхней части изображён исходный образец, ниже – реконструкция, сформированная автоэнкодером.

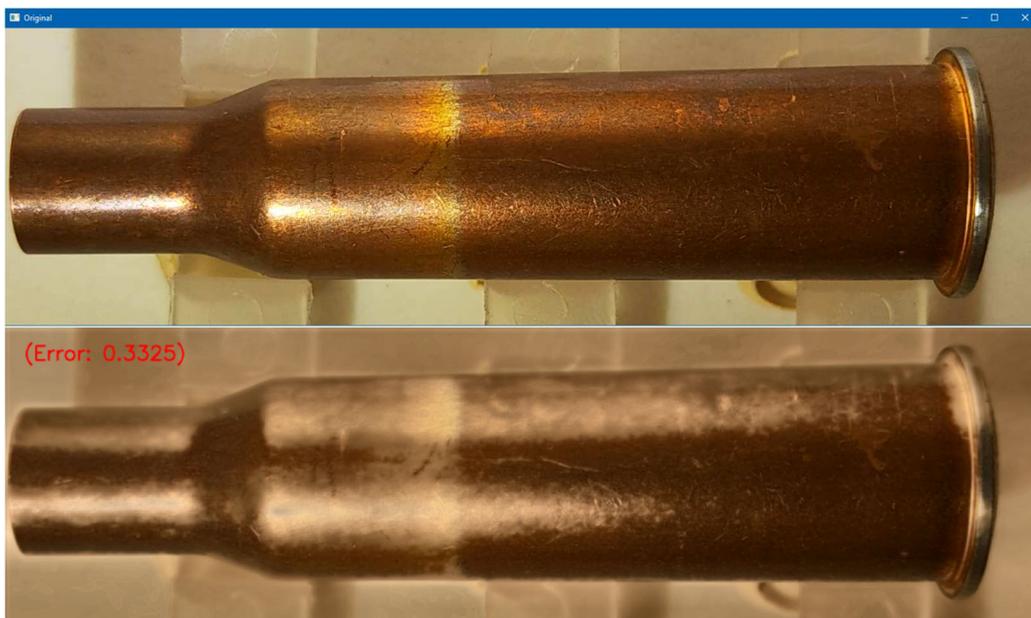


Рис. 7. Вывод реконструкции с камеры

Результаты и обсуждение

Результаты работы всех алгоритмов и сравнение результатов приведены в табл. 2. Представлена усредненная ошибка реконструкции для разной яркости нормализации в статике и в динамике.

Таблица 2

Исходные данные		Яркость нормализации, относительные единицы				
Измерение	Гильза	20	60	80	100	120
Статика	Целая	0,0187	0,05265	0,0322	0,0457	0,0534
	Дефект	0,0190	0,05825	0,0485	0,0691	0,0740
Динамика	Целая	0,0274	0,1752	0,1729	0,3325	0,3285
	Дефект	0,0286	0,1814	0,1733	0,3288	0,3373

Усреднённая ошибка реконструкции при разных яркостях и контрасте 20

При изменении условий освещения требуется дополнительное обучение модели, поскольку она проявляет высокую чувствительность к вариациям теней на поверхности объектов.

В текущей модели наблюдаются ложные срабатывания на шероховатости поверхности корпуса и разные вариации цвета гильз, как показано на рис. 8, что связано с ограниченным объемом обучающих данных. В обучающей выборке отсутствуют патроны с различающимся цветом корпуса.

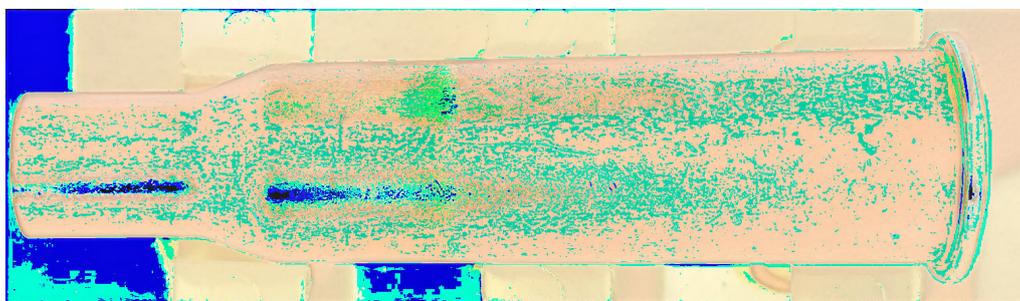


Рисунок 8 – Тепловая карта ошибки реконструкции

Так же при неглубоком слое «растянутый» вход (как 1552×448) может давать слишком узкое покрытие по вертикали, снижая чувствительность к дефектам, ориентированным «вширь», при этом модель крайне чувствительна к освещению и бликам [10]. Модель дает незначительную уверенность.

Заключение

В ходе настоящего исследования был разработан подход на базе сверточного автокодировщика, эксперименты в статическом режиме подтвердили возможность обеспечить хорошую точность разделения бездефектных и дефектных

образцов, тогда как в ходе анализа результатов динамической обработки видеопотока выявлена необходимость расширения обучающей выборки и доработки алгоритма для обеспечения стабильности получаемого результата в реальном времени.

В дальнейших исследованиях планируются оптимизация архитектуры модели и методов аугментации данных, а также внедрение специализированных приёмов компенсации теневых артефактов и вариаций цвета для повышения надёжности детекции при разнообразных условиях съёмки.

Для повышения устойчивости модели к вариациям освещения требуется обучение на данных, полученных при различных положениях источника света, либо применение методов минимизации теневых эффектов.

Динамическую детекцию целесообразно дополнительно оптимизировать за счёт расширения обучающего датасета.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Федотов И.С. Трансферное обучение в компьютерном зрении: применение и перспективы. Вестник науки (2023). – 9(66). – С. 135–137.
2. Чернышов Ю. Ю. Применение автокодировщиков для выявления аномалий в киберфизических системах. Вестник пермского университета. Математика. Механика. Информатика (2022). – 4(59). – С. 89–94.
3. Камалова Ю. Б., Андриянов Н. А. Распознавание микроскопических изображений пылевых зерен с помощью сверточной нейронной сети VGG-16. Вестник Южно-Уральского государственного университета (2022). – 22(3). – С. 39–46.
4. Ломовцева Н.А., Кувайскова Ю.Е. Использование модуля нейронных сетей в системе Statistica для решения задачи классификации. Известия Южного федерального университета. Вестник Ульяновского государственного технического университета (2021). – 4(104). – С. 59–61.
5. Маршалко Д.А. Кубанских О.В. Архитектура свёрточных нейронных сетей. Ученые записки Брянского государственного университета (2019). – 2(30). – С. 10–13.
6. Скороход А.В., Гордиенко М.В., Семенкин Е.С. Введение в глубинные нейронные сети. Актуальные проблемы авиации и космонавтики (2020). – 3. – С. 83–85.
7. Кудяшов А. А., Новикова А. А. Оценка качества колоризации изображений природного ландшафта нейросетевого автокодировщика. Инженерный вестник Дона (2024). – 7. – С. 3–14.
8. Xu Z., Qian S., Ran X., Zhou J. Application of Deep Convolution Neural Network in Crack Identification. Applied Artificial Intelligence (2022). – 36(1). – Pp. 1–22.
9. Pak V., Ugli A. S. Application of transfer learning for medical image classification. Science, technology and education (2020). – 4(92). – Pp. 39–42.
10. Wei W., Xu X. Application of crack detection algorithm using convolutional neural network in concrete pavement construction. International Journal of Grid and Utility Computing (2022). – 13(2-3). – Pp. 154–163.

© Р. М. Новиков, Д. Н. Титов 2025