

УДК: 004.932

ОБНАРУЖЕНИЕ ДЕФЕКТОВ КЕРАМИЧЕСКИХ ПОКРЫТИЙ МЕЛКОГАБАРИТНЫХ ИЗДЕЛИЙ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОМЫШЛЕННОГО КОНТРОЛЯ КАЧЕСТВА

С. В. Спицын, к.т.н., ведущий инженер-программист АО «Моринсис-Агат-КИП», доцент кафедры САПР ВС РГРТУ Рязань, Россия;

orcid.org/0000-0001-6468-5043, e-mail: spitsyn62@gmail.com

С. С. Румянцев, начальник отдела обеспечения ГОЗ АО «Моринсис-Агат-КИП», Рязань, Россия;

orcid.org/0009-0006-6102-3902, e-mail: R0806rus@yandex.ru

Рассматривается технология применения свёрточных нейронных сетей для автоматизированного обнаружения и классификации дефектов на керамических покрытиях мелкогабаритных изделий в условиях промышленного контроля качества. Приведены результаты экспериментов, подтверждающие эффективность предложенного подхода, включая метрики оценки качества ML-модели и их численные показатели. Также представлены характеристики видеокамеры, использованной для получения изображений, размеры обучающей, тестовой и валидационной выборок. Актуальность исследования обусловлена необходимостью повышения эффективности контроля качества в масштабе промышленного производства, где традиционные методы визуального осмотра являются достаточно трудоёмкими и дающими субъективный результат.

Целью работы является повышение точности и скорости контроля качества мелкогабаритных керамических изделий путем использования передовых методов машинного обучения.

В ходе исследования решались следующие задачи: сбор и разметка датасета изображений керамических покрытий, полученных с монохромной видеокамеры высокого разрешения по интерфейсу GigE Vision; обучение ML-модели для поиска трещин, сколов, пятен и других видов дефектов керамики, оптимизация гиперпараметров модели; оценка качества работы модели с использованием общепринятых метрик классификации и регрессии, таких как показатель средней точности mAP, precision, recall, и F1-score. Полученные результаты демонстрируют достаточно высокую эффективность предложенной технологии для автоматизации контроля качества мелкогабаритных керамических изделий, что позволяет значительно сократить время проверки изделия по сравнению с «ручным» осмотром.

Ключевые слова: машинное обучение, обнаружение дефектов, промышленный контроль качества, компьютерное зрение, свёрточные нейронные сети.

DOI: 10.21667/1995-4565-2025-93-83-91

Введение

Благодаря высокой термостойкости, коррозионной устойчивости и износостойкости, керамические покрытия широко применяются в различных отраслях промышленности, включая радиоэлектронную промышленность, энергетику и медицинскую технику. На эксплуатационные характеристики таких изделий напрямую влияет их качество, поэтому выявление дефектов на их поверхности является важной производственной и эксплуатационной задачей.

Традиционные методы дефектоскопии мелкогабаритных изделий из керамики, основанные на ручном визуальном осмотре, имеют ряд понятных всем недостатков – они требуют значительных временных затрат, зависят от опыта контролера и носят субъективный характер. Кроме того, такие методы не всегда позволяют эффективно анализировать крупные объёмы данных, что ограничивает их применение в условиях массового производства.

Развитие глубокого машинного обучения (ML) и компьютерного зрения (CV) открывает новые возможности для автоматизации процессов технологического контроля [1]. Архитектура свёрточных нейронных сетей и численных алгоритмов обработки изображений в настоящее время продемонстрировали высокую эффективность в задачах обнаружения и классификации различных объектов в режиме реального времени [2-4]. Применительно к дефектоскопии современные нейросетевые алгоритмы способны выявлять микродефекты, которые сложно обнаружить при визуальном осмотре, а также обеспечивать воспроизводимость и объективность результатов. В данной работе рассматривается применение методов машинного обучения для автоматизированного анализа керамических покрытий, оцениваются их преимущества по сравнению с традиционными подходами и обсуждаются перспективы дальнейшего развития данной технологии. Основное внимание будет уделено определению различного рода дефектов, таких как трещины, сколы, пятна и рытвины, на самой первой стадии жизненного цикла керамического изделия – стадии его конвейерного производства.

Постановка задачи

Задача исследования формулируется следующим образом: для заданного изображения керамического покрытия необходимо определить наличие, локализацию и классификацию дефектов (трещины, сколы, пятна, рытвины) с помощью ML-модели на основе свёрточных нейронных сетей (CNN) [5]. Локализация должна быть выполнена по всей поверхности исследуемого прямоугольного объекта (2 фронтальные и 4 боковые поверхности, итого: 6 изображений) в абсолютных (по пикселям) координатах исходного изображения либо в нормализованных координатах исходного изображения в диапазоне от 0 до 1.

Математическая формулировка задачи сводится к минимизации функции потерь, включающей компоненты для предсказания ограничивающих рамок дефектов (*bounding box*) и достоверности детекции и классификации дефектов (*confidence score*) [6,7].

Теоретическая часть

Для решения поставленной задачи объектной детекции с многоклассовой классификацией в настоящее время наиболее успешно применяются предобученные CNN архитектуры, такие как *Faster R-CNN*, *SSD (Single Shot MultiBox Detector)* и аналогичные. Такие CNN модели обеспечивают высокую точность классификации и скорость обработки изображений, что делает их наиболее подходящими для применения в условиях автоматизированного промышленного производства. По своей архитектуре они представляют собой классические многослойные структуры, предназначенные для обработки двумерных изображений, включающие в себя свёрточные слои (выделение признаков изображений), слои подвыборки (сокращение размерности данных), полносвязные слои (преобразование признаков в предсказание) и функцию активации для определения степени отклика нейронов. В данном исследовании используется CNN архитектура, выполняющая детекцию, локализацию и классификацию за один проход по изображению, что потенциально делает её эффективной для промышленных задач автоматизации, решаемых в режиме реального времени.

Минимизация общей функции потерь L представляет собой минимизацию всех её компонентов [4]:

$$L = L_{loc} + L_{conf} + L_{cls},$$

где L_{loc} – функция потерь локализации, т.е. ошибка в предсказании координат границ дефекта (x, y, l, h) :

$$L_{loc} = \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2].$$

В задачах компьютерного зрения для представления объектов на изображении в формате ограничивающих рамок широко используются формулы координат верхнего левого пикселя

(x_l, y_l) , координат нижнего правого (x_2, y_2) , координат центра (x_0, y_0) , ширины (l) и высоты (h) ограничивающей рамки:

$$x_1 = x_0 - \frac{l}{2}, \quad y_1 = y_0 - \frac{h}{2}, \quad x_2 = x_0 + \frac{l}{2}, \quad y_2 = y_0 + \frac{h}{2},$$

$$x_0 = \frac{x_1 + x_2}{2}, \quad y_0 = \frac{y_1 + y_2}{2}, \quad l = x_2 - x_1, \quad h = y_2 - y_1;$$

L_{conf} – функция потерь достоверности (степень уверенности модели в том, что предсказанный объект является дефектом):

$$L_{conf} = \lambda_{noobj} \sum_{i=1}^{S^2} \sum_{j=1}^B 1_{ij}^{noobj} (C_i - \hat{C}_i)^2;$$

L_{cls} – функция потерь классификации, т.е. ошибка в определении класса дефекта (трещина, скол, пятно, рытвина):

$$L_{cls} = \sum_{i=0}^{S^2} 1_j^{noobj} \sum_{c \in classes} (p_i(c) - \hat{p}_i(c))^2,$$

где S – размер сетки; B – количество ограничивающих рамок; 1_{ij}^{obj} – индикатор наличия дефекта в j -й ограничивающей рамке i -й ячейки; λ_{coord} и λ_{noobj} – коэффициенты для балансировки компонент потерь; C_i и $\hat{C}_i$ – истинное и предсказанное моделью значение достоверности в диапазоне от 0 до 1 (т.е. наличие объекта в i -ой ограничивающей рамке). Таким образом, составляющая $(C_i - \hat{C}_i)^2$ является MSE между предсказанным и истинным значениями достоверности.

Классический расчет осуществляется с помощью сигмоиды: $C_i = \sigma(t_i) = \frac{1}{1 + e^{-t_i}}$. В данной работе в качестве метрики локализации дефекта на монохромном изображении керамического покрытия рассматривалась функция потерь $CloU Loss$, которая учитывает не только IoU перекрытие, но и расстояния между центрами и соотношение сторон объектов:

$$L_{CloU} = 1 - IoU + \frac{p^2(b, b^s)}{c^2} + \alpha v,$$

где $p^2(b, b^s)$ – евклидово расстояние между центрами ограничивающих рамок b и b^s ; c – диагональ минимального прямоугольника, охватывающего рамки; α – весовой коэффициент; v – мера различия соотношений сторон. Для оценки качества модели примем общепринятые ML -метрики: средняя точность обнаружения дефектов на изображении керамической поверхности (mAP), доля правильно предсказанных дефектов среди всех обнаруженных ($precision$), доля правильно обнаруженных дефектов среди всех присутствующих на изображении ($recall$), а также гармоническое среднее последних двух метрик – $F1-score$ [1, 8].

Предобработка данных и процесс обучения модели

В рамках исследования последовательно выполнялись следующие этапы формирования датасета исходных снимков поверхностей и предобработки данных.

1. Сбор изображений двух фронтальных и четырёх боковых поверхностей прямоугольных керамических изделий с помощью монохромной видеокамеры высокого разрешения по интерфейсу *GigE Vision*.

2. Разметка полученных изображений, определение координат ограничивающих рамок дефектов и присвоение им классов [9].

3. Увеличение вариативности обучающей выборки посредством изменения глубины резкости, яркости и контрастности изображений.

4. Выделение обучающего, валидационного и тестового подмножеств из общего массива полученных изображений.
5. Обучение модели и оптимизация гиперпараметров.

Экспериментальные исследования

Для получения и разметки изображений керамических поверхностей, а также их категоризации и дополнения описательными данными, помогающими в идентификации и классификации типов дефектов в рамках исследования, был разработан специальный автоматизированный стенд (рисунок 1), состоящий из поворотной платформы (рисунок 2), источников освещения, фронтальной и боковой видеокамеры и специального программного обеспечения для аннотирования. Получение первого фронтального и бокового снимка и трёх последующих снимков боковых поверхностей производилось с интервалом в 1 с путём выполнения микропрограммы поворотной платформы с последующим отображением полученных проекций керамического изделия на мониторе специального программного обеспечения.




Рисунок 1 – Автоматизированный стенд для получения и аннотирования изображений исходного датасета

Figure 1 – Automated stand to obtain and annotate images for original dataset

Рассматривались 2 типа мелкогабаритных прямоугольных изделий из алюмооксидной керамики Al_2O_3 со следующими габаритами: тип А: $4 \times 4 \times 2$ мм, тип В: $7 \times 7 \times 3$ мм. Назначение керамических изделий – радиоэлектронная промышленность. Изображения были получены полуавтоматизированным путём, так как для получения снимка второй фронтальной поверхности требовался ручной переворот изделия оператором. Последующие тестовые «прогоны» единичного керамического изделия (имитация рабочего технологического процесса контроля качества на отдельно взятом производстве) проводились на этом же испытательном стенде. Для получения монохромных изображений керамических покрытий использовались 2 промышленные камеры со следующими характеристиками: тип сенсора: CMOS; модель сенсора: Sony IMX249; размер пикселя: $5,86 \text{ мкм} \times 5,86 \text{ мкм}$, разрешение: 1920×1200 пикселей (2,3 МП), максимальная частота кадров: 41 кадр/с при полном разрешении, интерфейс передачи данных: GigE. Датасет из 100 исходных изображений был разделён следующим образом: обучающая выборка: 70 % данных, валидационная выборка: 15 % данных, тестовая выборка: 15 % данных, начальная скорость обучения: 0,001, размер батча: 16, число эпох обучения: 200. Обобщенная CNN архитектура используемой модели представляла собой классическую однопроходную детектирующую сеть, оптимизированную для задач сегментации и классификации с модифицированными CSP-C2f блоками для ис-

пользования большего количества скип-коннектов и постепенного уменьшения размерности изображения керамической поверхности при одновременном увеличении глубины признаков (Backbone). Для диверсификации мелких и крупных керамических дефектов введен слой PAN-FPN. Предсказание координат центров bbox осуществлялось напрямую без заранее заданных «якорей».




Рисунок 2 – 3D модель станда с платой управления и приводным механизмом
Figure 2 – 3D model of the stand with control board and drive mechanism

Предложенная конструкция с размещенной внутри нее платой управления поворотной платформой, шаговым двигателем и ременным приводом позволила получать проекции исследуемых объектов (с интервалом не более 1 с), аналогичные **классическому чертежу детали**, отображающему все поверхности керамического изделия. Этот аспект был реализован в специальном программном обеспечении (рисунок 3). Таким образом, технология исследования и получения итоговой проекции единичного изделия с детектированными и классифицированными дефектами сводилась к следующим основным этапам: 1) произвольное ручное размещение оператором мелкогабаритного керамического изделия на прозрачной, подсвеченной рассеянным светом поворотной платформе. В зависимости от типа керамики применялось также *UV* освещение; 2) автоматический и ускоренный первичный анализ фронтального изображения моделью на предмет «ровности» размещения изделия относительно боковой камеры; 3) автоматический «доворот» платформы посредством выполнения микропрограммы платы управления до угла, необходимого для получения качественного бокового снимка; 4) автоматический запуск циклограммы анализа изделия в специальном программном обеспечении; 5) автоматизированный «прогон» поворотной платформы, начинающийся с этапа одновременного получения снимка верхней грани и снимка первой боковой грани (*одновременная работа фронтальной и боковой камеры*); 6) последующие итоговые повороты платформы и получение всех оставшихся снимков боковых граней (*работа только боковой камеры*); 7) параллельная работа модели и анализ получаемых изображений специальным программным обеспечением с применением технологии многопоточной обработки; 8) завершение циклограммы анализа и ручной переворот оператором изделия для получения снимка нижней поверхности (*работа только фронтальной камеры*). Наиболее затратный по времени и требующий дополнительной автоматизации этап; 9) Получение итоговой проекции (рисунок 3) и предоставление оператору возможности ручного аннотирования и классификации дефектов с целью пополнения или корректировки исходного датасета изображений (исправление ошибок или «дообучение» модели).

Классификация дефектов керамики при аннотировании установлена как: 0 – скол, 1 – трещина, 2 – пятно, 3 – рытвина. Результаты выполнения детекции и классификации вышеперечисленных дефектов на тестовом наборе данных продемонстрировали высокие пока-

затели метрик качества модели: точности, полноты, потерь классификации и средней точности детектирования (рисунок 4).



Рисунок 3 – Проекция керамического изделия

Figure 3 – Projection of ceramic product




Рисунок 4 – Ключевые метрики модели в процессе обучения и валидации

Figure 4 – Key model metrics during training and validation

Результаты локализации ограничивающих рамок дефектов и частота детекции различных типов дефектов представлены на рисунке 5.




Рисунок 5 – Результаты локализации ограничивающих рамок дефектов

Figure 5 – Results of defect bounding boxes localization

Результаты детекции и классификации при валидации и тестовом наборе представлены на комбинированном снимке (рисунок 6).




Рисунок 6 – Результаты детекции и классификации на комбинированном снимке
Figure 6 – Detection and classification results on combined image

Заключение

В результате проведённого исследования были подтверждены возможность и эффективность обнаружения дефектов на керамических покрытиях с помощью *CNN* моделей с применением технологии полуавтоматизированного получения проекций мелкогабаритных объектов с дополнительной возможностью ручного аннотирования и классификации дефектов, а также пополнения и коррекции исходного датасета снимков. Показатели эффективности задействованной в технологии отдельно рассматриваемой модели составили: *precision* 82 %, *recall* 80 %, *F1-score* 82 % и *mAP* 91 % при среднем времени цикла получения и анализа снимков двух фронтальных и четырёх боковых поверхностей единичного мелкогабаритного керамического изделия 5 с. Результаты исследования подтверждают возможность сокращения времени, затрачиваемого на осуществление технологического контроля качества мелкогабаритных изделий из керамики в условиях промышленного производства по сравнению с традиционными методами контроля. Разработанная технология может быть эффективно внедрена на производственных линиях и является объектом дальнейших исследований в части оптимизации алгоритмов (детекция, локализация, классификация) и интеграции с системами промышленной автоматизации.

Библиографический список

1. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. New York: Springer, 2009. 745 p. (Springer Series in Statistics). ISBN 978-0-387-84857-0.
2. Меняйлов Д.В., Преображенский А.П. Сравнительный анализ результатов, полученных при решении задачи анализа тональности текста с помощью свёрточной и рекуррентной нейронных сетей // Моделирование, оптимизация и информационные технологии. 2021. Т. 9, № 4 (35). DOI: 10.26102/2310-6018/2021.35.4.012.
3. Бондаренко В.А., Павлова В.А., Тупиков В.А., Холод Н.Г. Нейросетевой алгоритм полнокадрового распознавания надводных объектов в реальном времени // Известия ЮФУ. Технические науки. 2020. № 1 (211). С. 188-199.
4. Басс Л.П., Кузмина М.Г., Николаева О.В. Свёрточные нейронные сети с глубоким обучением в задачах обработки гиперспектральных спутниковых данных // Препринты ИПМ им. М.В. Келдыша. 2018. № 282.

5. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 770-778.
6. Ren S., He K., Girshick R., Sun J. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2017. Vol. 39. № 6. P. 1137-1149.
7. Zheng Z., Wang P., Liu W., Li J., Ye R., Ren D. Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression // AAAI. 2020. P. 12993-13000.
8. Padilla R., Passos W.L., Dias T.L.B., Netto S.L., da Silva E.A.B. A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit // Electronics. 2021. Vol. 10. № 3. P. 279.
9. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks // Communications of the ACM. 2017. Vol. 60. № 6. P. 84-90.

UDC 004.932

DETECTION OF CERAMIC COATING DEFECTS ON SMALL-SIZED PRODUCTS USING CONVOLUTIONAL NEURAL NETWORKS FOR INDUSTRIAL QUALITY CONTROL

S. V. Spitsyn, PhD, Leading Software Engineer, JSC Morinsystem-Agat-KIP, Associate Professor, RSREU, Ryazan, Russia;

orcid.org/0000-0001-6468-5043, e-mail: spitsyn62@gmail.com

S. S. Rumyancev, Head of the State Defense Order Support Department, JSC Morinsystem-Agat-KIP, Ryazan, Russia;

orcid.org/0009-0006-6102-3902, R0806rus@yandex.ru

*The article considers the technology of using convolutional neural networks for automated detection and classification of defects on ceramic coatings of small-sized products in industrial quality control conditions. The results of experiments confirming the effectiveness of proposed approach including metrics for assessing the quality of ML model and their numerical indicators are presented. The characteristics of video camera used to obtain images, training sizes; test and validation samples are also presented. The relevance of study is the necessity to improve the efficiency of quality control on industrial production scale where traditional methods of visual inspection are quite labor-intensive and give subjective results. **The aim of the work** is to increase accuracy and speed of quality control of small-sized ceramic products using advanced machine learning methods.*

During the study the following tasks were solved: collecting and marking of ceramic coatings images dataset obtained from high-resolution monochrome video camera via GigE Vision interface; training ML model to search for cracks, chips, stains and other types of ceramic defects, optimizing model hyperparameters; evaluation of model quality using generally accepted classification and regression metrics, such as average accuracy rate mAP, precision, recall, and F1-score. The results obtained demonstrate fairly high efficiency of the proposed technology for automating the quality control of small-sized ceramic products which allows us to significantly reduce inspection time compared to «manual» inspection.

Keywords: machine learning, defect detection, industrial quality control, computer vision, convolutional neural networks.

DOI: 10.21667/1995-4565-2025-93-83-91

References

1. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. New York: Springer, 2009. 745 p. (*Springer Series in Statistics*). ISBN 978-0-387-84857-0.
2. Menyajlov D.V., Preobrazhenskij A.P. Sravnitel'nyj analiz rezul'tatov, poluchennykh pri reshenii zadachi analiza tonal'nosti teksta s pomoshch'yu svyortchnoj i rekurrentnoj nejronnykh setej. *Modelirovanie, optimizaciya i informacionnye tekhnologii*. 2021, vol. 9, no. 4 (35). DOI: 10.26102/2310-6018/2021.35.4.012. (in Russian).

3. **Bondarenko V.A., Pavlova V.A., Tupikov V.A., Kholod N.G.** Nejrosetevoj algoritm polnokadrovogo raspoznavaniya nadvodnykh ob"ektov v real'nom vremeni. *Izvestiya YUFU. Tekhnicheskie nauki*. 2020, no. 1 (211), pp. 188-199.
4. **Bass L.P., Kuz'mina M.G., Nikolaeva O.V.** Svyortochnye nejronnye seti s glubokim obucheniem v zadachakh obrabotki giperspektral'nykh sputnikovykh dannyykh . *Preprinty IPM im. M.V. Keldysha*. 2018. no. 282.
5. **He K., Zhang X., Ren S., Sun J.** Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016, pp. 770-778.
6. **Ren S., He K., Girshick R., Sun J.** Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks . *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017, vol. 39, no. 6, pp. 1137-1149.
7. **Zheng Z., Wang P., Liu W., Li J., Ye R., Ren D.** Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression. *AAAI*. 2020, pp. 12993-13000.
8. **Padilla R., Passos W.L., Dias T.L.B., Netto S.L., da Silva E.A.B.** A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. *Electronics*. 2021, vol. 10, no. 3, p. 279.
9. **Krizhevsky A., Sutskever I., Hinton G.E.** ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*. 2017, vol. 60, no. 6, pp. 84-90.