

УДК 519.688

Обнаружение дефектов на изображениях изделий в условиях Индустрии 4.0

Амирханян Лиана Гариковна

amirkhanyan.l@bmstu.ru

SPIN-код: 7569-2074

МГТУ им. Н.Э. Баумана, Москва, Россия

Аннотация. В условиях современного промышленного производства критически важно обеспечивать высокое качество выпускаемой продукции. Жесткие требования стандартов, минимизация допусков и необходимость отслеживания каждой единицы изделия в совокупности с ростом скоростей производства формируют комплексную технологическую задачу. Традиционные методы контроля, основанные на ручном осмотре, зачастую неэффективны из-за человеческого фактора, низкой скорости и высокой стоимости. Одним из наиболее перспективных направлений в этой области является применение методов компьютерного зрения и глубокого обучения для обнаружения дефектов на изображениях изделий. Рассмотрены основные подходы к обнаружению дефектов, их преимущества и ограничения.

Ключевые слова: сверточные нейронные сети, Индустрия 4.0, детекция дефектов, глубокое обучение, автоматический визуальный контроль

Detection of defects in product images in Industry 4.0 conditions

Amirkhanyan Liana Garikovna

amirkhanyan.l@bmstu.ru

SPIN-code: 7569-2074

BMSTU, Moscow, Russia

Abstract. In modern industrial production, it is critically important to ensure high quality of manufactured products. Strict standards, minimization of tolerances, and the need to track each unit of production, combined with increasing production speeds, create a complex technological challenge. Traditional control methods based on manual inspection are often ineffective due to human error, low speed, and high cost. One of the most promising areas in this field is the use of computer vision and deep learning methods to detect defects in product images. The main approaches to defect detection, their advantages and limitations are considered.

Keywords: convolutional neural networks, Industry 4.0, defect detection, deep learning, automatic visual inspection

Введение. Автоматический визуальный контроль (АВК) представляет собой важный элемент концепции Индустрии 4.0, способствующий повышению качества продукции, снижению затрат и переходу к предиктивному обслуживанию. Задача АВК формулируется в контексте компьютерного зрения и включает классификацию изображений (определение дефектного или без-

дефектного состояния), детекцию (локализацию дефекта с использованием ограничивающей рамки) [1]. Суть использования этих технологий заключается в создании алгоритмических систем, способных автоматически извлекать семантически значимую информацию из цифровых изображений или видеопотоков, полученных с промышленных камер, и классифицировать ее на предмет соответствия эталону. Процесс классификации и детекции включает в себя несколько этапов: предварительная обработка изображений, извлечение признаков, применение моделей машинного обучения для классификации и последующая верификация результатов. Использование таких технологий позволяет не только повысить уровень автоматизации процессов контроля качества, но и снизить вероятность человеческой ошибки, что является важным фактором в обеспечении стабильности производственных процессов.

Методы и материалы; результаты. Современные подходы к обнаружению дефектов на изображениях основываются на использовании сверточных нейронных сетей (CNN) [2], алгоритмов машинного обучения и методов обработки изображений. Эти методы можно классифицировать на две основные группы.

1. Контролируемое обучение. Это наиболее распространенный подход, который требует наличия обширного аннотированного датасета изображений, где каждый дефект четко размечен [3]. Оно требует значительных ресурсов для подготовки данных, так как создание аннотированных наборов изображений может быть трудоемким и времязатратным процессом. Однако наличие таких данных позволяет достичь высокой точности в задачах классификации и локализации дефектов. В рамках этого подхода применяются методы детектирования объектов, среди которых выделяются архитектуры сверточных нейронных сетей, такие как Faster R-CNN, YOLO и SSD. Эти модели позволяют не только классифицировать дефекты (например, определять наличие царапин, сколов или включений), но и локализовать их на изображении с помощью ограничивающих прямоугольников. Кроме того, существует группа технологий, основанных на семантической сегментации, где архитектуры, такие как U-Net и Mask R-CNN, решают задачу на уровне пикселей, присваивая каждому пикселю определенный класс. Это обеспечивает возможность получения точной маски дефекта произвольной формы, что позволяет проводить дальнейший количественный анализ, включая вычисление площади, периметра и ориентации дефекта.

2. Обучение без учителя или слабо контролируемое обучение. Эти подходы предполагают самостоятельное выявление закономерностей в неразмеченных данных [4]. Одним из методов обнаружения аномалий является использование автоэнкодеров, которые обучаются на уменьшении входных данных и восстановлении их в исходное состояние из сжатого представления после обработки. Также в данной категории выделяются генеративно-состязательные сети (GANs), которые применяются для аугментации данных и синтеза изображений дефектов в условиях нехватки реальных образцов для

обучения [5]. Кроме того, существует подход с использованием слабых методов, при котором модель обучается на данных, размеченных лишь по общей принадлежности к классу «дефектное/бездефектное», без указания точного расположения дефектов.

Компьютерное зрение представляет собой мощный инструмент для автоматизации процессов контроля качества в производственной сфере. Его применение приносит ряд значительных преимуществ, которые способствуют повышению эффективности и надежности производственных процессов.

1. Увеличение скорости проверки: автоматизированные системы на основе компьютерного зрения способны обрабатывать изображения в реальном времени. Это позволяет значительно ускорить процесс контроля качества по сравнению с традиционными методами, основанными на ручном осмотре. В условиях массового производства такая скорость является критически важной, так как позволяет минимизировать время простоя и повысить производительность.

2. Повышение точности: алгоритмы глубокого обучения, используемые в системах компьютерного зрения, демонстрируют высокую точность обнаружения дефектов. Они могут выявлять даже незначительные отклонения от нормы, что часто недоступно для человеческого восприятия. Это приводит к снижению количества пропущенных дефектов и, как следствие, к повышению качества конечного продукта.

3. Снижение затрат: автоматизация контроля качества способствует значительному снижению трудозатрат, что, в свою очередь, ведет к уменьшению общих производственных расходов. Системы компьютерного зрения могут заменить или существенно сократить количество сотрудников, занимающихся визуальным контролем, что позволяет перераспределить ресурсы на более сложные задачи.

4. Масштабируемость: автоматизированные системы легко адаптируются к изменяющимся объемам производства. В отличие от человеческого труда, который требует значительных усилий для увеличения рабочей силы, системы компьютерного зрения могут быть быстро развернуты и настроены под новые условия без необходимости в значительных дополнительных инвестициях.

5. Сбор данных для анализа: компьютерные системы контроля качества способны собирать и хранить обширные объемы данных о производственном процессе. Эти данные могут быть использованы для проведения глубокого анализа причин возникновения дефектов, что позволяет выявлять узкие места в производственной цепочке и оптимизировать процессы для повышения общей эффективности.

Несмотря на многочисленные преимущества, внедрение технологий машинного обучения в контроль качества также сопряжено с определенными ограничениями и вызовами.

1. Необходимость больших объемов данных: для обучения моделей глубокого обучения требуется значительное количество размеченных изображений, что может быть труднодоступно в некоторых отраслях. Сбор и анноти-

рование таких данных требуют времени и ресурсов, что может стать препятствием для быстрого внедрения автоматизированных систем.

2. В некоторых случаях дефекты занимают лишь небольшую часть изображения, что затрудняет их обнаружение. Этот дисбаланс может привести к низкой точности модели, так как алгоритмы могут не обучаться должным образом на недостаточно представленных классах.

3. Глубокие нейронные сети часто воспринимаются как «черные ящики», что затрудняет анализ причин ошибок. Определить, какие именно особенности входных данных привели к ошибке, требует значительных усилий.

Заключение. Таким образом, обнаружение дефектов на изображениях изделий является важным элементом автоматизации контроля качества в условиях Индустрии 4.0. Применение современных методов глубокого обучения и компьютерного зрения открывает новые возможности для повышения эффективности производства. Однако для достижения максимальной производительности необходимо преодолеть существующие ограничения и продолжить исследование новых подходов и технологий. Это позволит обеспечить более высокий уровень качества продукции и повысить конкурентоспособность предприятий в условиях быстро меняющегося рынка.

Список источников

- [1] Huang S.H., Pan Y.C. Automated visual inspection in the semiconductor industry: A survey. *Computers in industry*, 2015, vol. 66, pp. 1–10.
- [2] Badmos O. et al. Image-based defect detection in lithium-ion battery electrode using convolutional neural networks. *Journal of Intelligent Manufacturing*, 2020, vol. 31, no. 4, pp. 885–897.
- [3] Burkart N., Huber M.F. A survey on the explainability of supervised machine learning. *Journal of Artificial Intelligence Research*, 2021, vol. 70, pp. 245–317.
- [4] Schlegl T. et al. f-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks. *Medical image analysis*, 2019, vol. 54, pp. 30–44.
- [5] Saxena D., Cao J. Generative Adversarial Networks (GANs): Challenges, Solutions, and Future Directions. *ACM Comput. Surv.*, 2021, vol. 54, no. 3, art. no. 63, 42 p.