

УДК 004.89

ИСМАГУЛОВ С.Е., студент гр. ПИ416 (ЮГУ)

ДОЛМАТОВА М.А., студент гр. ПИ416 (ЮГУ)

ЛЕЙКО Е.А., студент гр. ПИ416 (ЮГУ)

РАССКАЗОВ М.М., студент гр. ПИ416 (ЮГУ)

Научный руководитель ШЕВЧЕНКО А.С., к.ф.-м.н., доцент (ЮГУ)

г. Ханты-Мансийск

ПРИМЕНЕНИЕ СИСТЕМ КОМПЬЮТЕРНОГО ЗРЕНИЯ ДЛЯ АВТОМАТИЧЕСКОЙ ДЕТЕКЦИИ ДЕФЕКТОВ ИЗДЕЛИЙ В ПРОМЫШЛЕННОСТИ

Качество продукции на производстве является одним из ключевых факторов. Трещины и неровности на деталях могут привести к временным, материальным и финансовым убыткам. Брак, попавший к заказчику, возвращается обратно, а в некоторых случаях приводит к остановке всей производственной линии. На заводах, где производят важные части для машин, трубы или электронные платы, требуется повышенный контроль качества. Поэтому проверка качества занимает важное место на всех этапах производства.

Традиционный контроль с участием человека требует визуального осмотра изделия и принятия решения о наличии или отсутствии дефектов. Однако такой подход имеет существенные ограничения, связанные с человеческим фактором: утомляемость, снижение концентрации и субъективность оценки. При длительной работе оператор может пропустить дефекты или, наоборот, ошибочно забраковать качественные изделия. Также скорость проверки ограничена возможностями оператора; особенно критично на высокоскоростных производственных линиях, где изделия проходят за короткое время. Это приводит к снижению качества контроля, либо к замедлению производства, что сказывается на прибыли [1].

В последние годы системы компьютерного зрения стали реальной альтернативой ручному контролю. Они анализируют изображения продукции автоматически – без участия оператора. Выявляют отклонения от заданных параметров, фиксируют дефекты, которые глазом не заметить: изменения текстуры, едва уловимые искажения формы. При этом точность и скорость анализа сильно зависят от специфики конкретного производства, это напрямую определяет, какие методы и алгоритмы обработки изображений выбирают [2].

В статье рассмотрены принципы работы систем компьютерного зрения для автоматической детекции дефектов, а именно: какие подходы используются и где они применяются.

На практике подобные системы уже работают в разных отраслях промышленности – примеры в таблице 1. Задачи при этом сильно расходятся: одно дело обнаружить микроскопический дефект, другое – отбраковать явно повреждённое изделие.

Таблица 1 – Примеры применения компьютерного зрения

Отрасль	Тип изделий	Виды дефектов	Особенности контроля
Металлургия	Листы, заготовки	Трещины, коррозия, вмятины	Сложности из-за отражающей поверхности
Электроника	Печатные платы	Ошибки пайки, смещение компонентов, отсутствие элементов	Требуется высокая точность и масштабирование
Текстиль	Ткани	Разрывы, пятна, неоднородность структуры	Анализ текстуры в реальном времени
Автомобилестроение	Детали, кузовные элементы	Сколы, царапины, деформации	Работа на конвейере, высокая скорость
Пищевая промышленность	Продукты, упаковка	Повреждения упаковки, загрязнения, неправильная форма	Гигиенические требования, вариативность объектов

В металлургии системы обычно анализируют поверхность – листы проката, трубы, заготовки. Дефекты тут непредсказуемы: трещина может быть тонкой как волос или уходить в сторону на несколько сантиметров. Металлическая поверхность при этом сама по себе неоднородна – она маскирует дефекты, и это приходится закладывать в настройку системы. Поэтому используют камеры с высоким разрешением и методы обработки, которые выделяют контрастные участки на фоне общего «шума» поверхности [3].

В электронике проверяют печатные платы – точность расположения компонентов и качество пайки. Тут системы работают иначе: изображение платы сравнивается с эталоном (reference-based inspection), и любое отклонение от шаблона фиксируется как дефект. [4].

В текстильной промышленности ищут пятна, разрывы нитей, утолщения, изменения структуры ткани. Часть дефектов видна только при определённом освещении или угле – это усложняет задачу. Системы работают в реальном времени, непрерывно анализируя поток изображений [5].

Отрасли разные, но требования схожие: высокая скорость обработки, устойчивость к внешним условиям, достаточная точность.

В связи с этим возникает вопрос: за счет каких именно механизмов достигаются указанные характеристики и как в целом организован процесс работы системы компьютерного зрения? Если рассматривать его в общем виде, то работа системы представляет собой не единый непрерывный процесс, а последовательность этапов, каждый из которых выполняет свою функцию по обработке изображения [3]. Для наглядности данный процесс можно представить в виде схемы, представленной на рисунке 1.




Рисунок 1. Схема работы системы компьютерного зрения

В начале процесса система получает изображения объекта контроля. Качество изображения играет ключевую роль, так как от него зависит, насколько корректно система сможет обнаружить дефекты в дальнейшем. Кроме того, важна стабильность условий съёмки. Если освещение или положение объекта постоянно меняются, то система начинает получать «разные» изображения одного и того же изделия, что существенно усложняет анализ. Для таких задач берут промышленные камеры – они рассчитаны на стабильную работу в условиях производства. [6].

Исходное изображение почти всегда содержит шумы и артефакты – это издержки работы камеры. Поэтому перед анализом его обрабатывают: сглаживающие фильтры убирают случайные помехи, нормализация яркости и контраста приводит изображения к единому виду. Последнее особенно важно, когда съёмка идёт в разных условиях освещения.

Из обработанного изображения извлекают признаки. Обычно начинают с контуров – они показывают границы объектов и дефектов. Трещина, например, выглядит как тонкая линия. Для тканей или поверхностей с повторяющимся рисунком важна текстура: система ищет неоднородности и нарушения узора [4].

Заключительный этап связан с принятием решения, есть ли дефект и, если есть, какого он типа. Классические подходы включают пороговые методы, при которых значение некоторого параметра сравнивается с заданным порогом. Их преимущество: относительная простота и понятность. Одним из таких методов является пороговая сегментация: её суть сводится к разделению изображения на области по значению яркости или цвета.

Также применяются методы SVM (метод опорных векторов), которые позволяют разделять данные на классы, на основе заранее выделенных признаков.

Все большее распространение получают сверточные нейронные сети (CNN) [5]. Такие модели хорошо работают в задачах, где дефекты имеют сложную структуру или значительно варьируются. Например, при контроле поверхности изделий с неоднородной текстурой классические методы могут давать нестабильный результат, тогда как нейронные сети способны обучаться распознавать подобные особенности. Однако для их применения требуется большое количество обучающих данных, а настройка таких моделей может быть достаточно трудоёмкой.

Для более наглядного сравнения классических методов и нейросетевых подходов их основные характеристики сведены в таблицу 2 [7].

Таблица 2 Сравнение методов обнаружения дефектов

Критерий	Классические методы	Методы на основе нейросетей
Accuracy	70–85%	85–98%
Precision	Средняя	До 90–95%
Recall	Низкая–средняя	До 90%+
F1-score	Ограниченный	Высокий
mAP	Обычно не применяется	До 0.95–0.98
Устойчивость к шумам	Низкая	Высокая
Требования к данным	Низкие	Высокие
Скорость обработки	Высокая	Средняя/высокая

Поэтому на практике используются комбинированные методы: например, изображения предварительно фильтруются классическими алгоритмами, после чего передаются в нейросеть. На этом этапе формируется окончательный результат, сигнал о наличии дефекта, который может использоваться для обработки изделия или передачи информации оператору.

Если рассматривать применение таких систем не только с точки зрения алгоритмов, но и в условиях реального производства, можно выделить их преимущества и ограничения.

Среди плюсов в первую очередь обычно отмечают высокую скорость контроля. Система способна обрабатывать поток изображений практически без задержек, что особенно заметно на линиях с большим объёмом продукции. Такие системы могут функционировать круглосуточно. Например, на крупных производствах это позволяет не останавливать линию для дополнительного контроля, а встроить проверку непосредственно в производственный процесс [6].

Есть и ограничения. Оборудование стоит дорого – камеры, освещение, разработка и настройка алгоритмов. Эффективность сильно зависит от внешних условий. Если используются нейросетевые методы, нужно обучать модели: размеченные данные, их сбор и подготовка – это отдельная трудоёмкая работа [5].

Системы компьютерного зрения дают реальный выигрыш в скорости и стабильности контроля – но требуют аккуратной настройки под конкретную задачу.

Они уже заняли устойчивое место в промышленном контроле качества. Эффективность определяется не только алгоритмами – важно качество изображения, условия съёмки, корректная настройка моделей. Всё это в связке.

Роль ИИ в промышленности будет только расти. Это вписывается в логику Industry 4.0 – интеграция цифровых технологий и автоматизация производства части одного процесса

Список литературы:

1. Pudussery, A. D. Computer Vision-Based Anomaly Detection in Industrial Components / A. D. Pudussery, A. Roy, I. R. Sainudheen // International Journal of Science and Advanced Technology. – 2025. – Vol. 16 (2). – Pp. 1-13. – URL: <https://www.ijسات.org/papers/2025/2/6154.pdf> (дата обращения: 04.04.2026).
2. Cheng, Y. A. Comprehensive Survey for Real-World Industrial Defect Detection: Challenges, Approaches, and Prospects / Y. A. Cheng, Y. Cao, H. Yao // arXiv. – 2025. – URL: <https://arxiv.org/abs/2507.13378> (дата обращения: 04.04.2026).
3. Jha, S. Deep CNN-based visual defect detection: Survey of current literature/ S. B. Jha, R. Babiceanu // Computers in Industry. – 2023. – Vol. 148. – P. 103911. – DOI: 10.1016/j.compind.2023.103911. – URL: <https://www.sciencedirect.com/science/article/abs/pii/S0166361523000611> (дата обращения: 04.04.2026)
4. Khanam R. Comprehensive Review of Convolutional Neural Networks for Defect Detection in Industrial Applications // IEEE Access. – 2024. – Vol. 4 – P. 1-41 – DOI: 10.1109/ACCESS.2024.3425166. – URL: <https://www.researchgate.net/publication/382102052> (дата обращения: 04.04.2026).
5. Li Z. A survey of deep learning for industrial visual anomaly detection // Artificial Intelligence Review. – 2025. – Vol. 58, No. 9. – P. 279. – DOI: 10.1007/s10462-025-11287-7. – URL: <https://www.researchgate.net/publication/392698522> (дата обращения: 04.04.2026).
6. Saberironaghi A. Defect Detection Methods for Industrial Products Using Deep Learning Techniques: A Review / Ren J., El-Gindy M. // Algorithms. – 2023. – Vol. 16, No. 2. – P. 95. – DOI: 10.3390/a16020095. – URL: <https://www.mdpi.com/1999-4893/16/2/95> (дата обращения: 04.04.2026).
7. Jiang Z. Defect R-CNN: A Novel High-Precision Method for CT Image Defect Detection // Applied Sciences. – 2025. – Vol. 15, No. 9. – P. 4825. – DOI: 10.3390/app15094825. – URL: <https://www.mdpi.com/2076-3417/15/9/4825> (дата обращения: 04.04.2026).

Информация об авторах:

Исмагулов Саян Ерикович, студент гр. ПИ416, ЮГУ, ул. Чехова, д. 16, г. Ханты-Мансийск, 628001, Россия, Ismagulov.s.e@yandex.ru

Рассказов Максим Максимович студент гр. ПИ416, ЮГУ, ул. Чехова, д. 16, г. Ханты-Мансийск, 628001, Россия, MaximaRasskazov@gmail.com

Долматова Мария Алексеевна, студент гр. ПИ416, ЮГУ, ул. Чехова, д. 16, г. Ханты-Мансийск, 628001, Россия, m_dolmatova03@bk.ru

Лейко Евгения Алексеевна, студент гр. ПИ416, ЮГУ, ул. Чехова, д. 16, г. Ханты-Мансийск, 628001, Россия, leiko.jane@gmail.com

Шевченко Алеся Сергеевна, к.ф.-м.н., доцент, ЮГУ, ул. Чехова, д. 16, г. Ханты-Мансийск, 628001, Россия, ibragimova.a.s@mail.ru

