

Разработка автоматизированной системы контроля качества драже с использованием машинного зрения и цифровых симуляций

В.Г. Благовещенский, М.В. Вежновец, Г.С. Квасов, М.П. Батурин,

Д.С. Киселев

Российский технологический университет МИРЭА, Москва

Аннотация: В данной статье представлена разработка автоматизированной системы контроля качества драже с применением технологий машинного зрения и цифрового моделирования. Целью работы является создание интеллектуальной системы, способной в реальном времени выявлять дефекты поверхности кондитерских изделий, такие как сколы и трещины. Предложенный подход сочетает обучение нейронной сети на основе архитектуры YOLO с использованием как реальных, так и синтетически сгенерированных изображений, а также внедрение цифровой симуляции производственной линии для предварительной отладки и оптимизации параметров системы. Использование цифровой модели позволяет проводить тестирование в условиях, приближённых к реальным, что способствует повышению точности классификации дефектов и снижению затрат на настройку оборудования. Проведённые испытания подтвердили высокую эффективность предложенной системы и целесообразность её внедрения в пищевую промышленность.

Ключевые слова: машинное зрение, контроль качества, драже, YOLO, цифровая симуляция, дефекты поверхности.

Введение

Современная пищевая промышленность активно внедряет технологии автоматизации и интеллектуального анализа данных, направленные на повышение качества продукции и снижение производственных издержек. Одним из приоритетных направлений является внедрение систем машинного зрения для автоматизации визуального контроля качества изделий [1, 2]. Особенно остро эта задача стоит в производстве кондитерской продукции, где даже незначительные дефекты на поверхности изделий — сколы, трещины, пробоины — могут привести к снижению товарной привлекательности и потере потребительской лояльности [3].

Драже, как форма кондитерского изделия с хрупкой оболочкой, подвержено механическим повреждениям при вибрации, соударении и в результате нарушений технологических режимов. Традиционные методы

контроля, основанные на выборочном осмотре оператором, обладают рядом существенных недостатков: они трудоёмки, субъективны и не могут обеспечить 100% проверку продукции на высокоскоростных линиях [4].

Технологии машинного зрения, основанные на применении нейросетевых архитектур, таких как YOLO, U-Net и Mask R-CNN, демонстрируют высокую эффективность при решении задач классификации и сегментации дефектов на поверхности пищевых изделий [5, 6]. Тем не менее, для успешного внедрения таких систем требуется точная настройка оборудования, выбор оптимальных углов обзора, режимов освещения и параметров захвата изображений, что часто невозможно провести непосредственно на действующем производстве из-за его непрерывного цикла. В этих условиях всё большую популярность приобретает использование цифровых двойников и виртуальных симуляций, позволяющих смоделировать производственный процесс, протестировать систему машинного зрения в различных сценариях и адаптировать её под нестандартные условия [7, 8].

Исходя из вышеизложенного, можно заключить, что разработка автоматизированной системы контроля качества даже на основе технологий машинного зрения и цифровой симуляции органично вписывается в современные тенденции цифровизации пищевой промышленности. Устойчивый спрос на продукцию стабильного качества, усиление требований к контролю безопасности пищевых изделий, а также стремление производителей к снижению доли бракованной продукции формируют потребность в интеллектуальных решениях, сочетающих гибкость, масштабируемость и промышленную надёжность. Предлагаемая система не только обладает высокой прикладной значимостью для производственных предприятий, но и характеризуется научной новизной благодаря

комплексному подходу, объединяющему нейросетевые методы анализа изображений и цифровые симуляции для адаптации под реальные условия эксплуатации.

Целью данной работы является разработка автоматизированной системы контроля качества драже на основе технологий машинного зрения и цифровых симуляций, обеспечивающей высокоточную детекцию дефектов и адаптацию к условиям реального производства.

Для достижения поставленной цели в работе решаются следующие задачи:

1. Проанализировать особенности дефектов поверхности драже и сформировать классификацию типовых повреждений (сколы, трещины, разрушения).
2. Разработать цифровую модель производственной линии, обеспечивающую возможность симуляции различных сценариев и условий съёмки.
3. Сформировать обучающий датасет, включающий как реальные, так и синтетические изображения изделий с различными дефектами на поверхности.
4. Обучить нейросетевую модель на основе YOLO для детекции дефектных изделий в потоке на конвейере.
5. Оценить точность, устойчивость и применимость разработанной системы в условиях промышленного производства.

В отличие от существующих решений, ориентированных преимущественно на применение классических алгоритмов обработки изображений или обучение нейросетей в условиях статичной съёмки, в данной работе предложен гибридный подход, сочетающий машинное зрение и цифровое моделирование производственного процесса. Это позволяет

адаптировать систему под широкий спектр условий: изменения освещения, нестандартную ориентацию объектов, вариативность формы и цвета драже. Научная новизна заключается в использовании цифровой симуляции не только как средства визуализации, но и как инструмента обратной связи и предварительной настройки системы технического зрения без вмешательства в реальную производственную среду, что обеспечивает более высокую точность и воспроизводимость результатов.

Для построения эффективной системы контроля качества необходимо предварительно проанализировать природу дефектов, возникающих на поверхности драже, и сформировать их структурированную классификацию. Повреждения, возникающие в процессе производства, хранения и транспортировки, могут существенно отличаться по морфологии, визуальным признакам и сложности обнаружения.

По результатам анализа собранного материала, в том числе визуальных данных с производственной линии и ручной инспекции, все дефекты на поверхности были условно разделены на три основных класса:

Сколы (локальные отломы фрагмента оболочки) — характеризуются отсутствием части внешнего слоя, в результате чего на поверхности образуется углубление с чёткой геометрической границей. Такие дефекты на поверхности, как правило, имеют ярко выраженную текстурную разницу между гладкой оболочкой и шероховатой внутренней частью. Сколы могут быть частичными (менее 25% от поверхности) или обширными (более 50%).

Трещины (волосяные или крупные линейные нарушения целостности) — представляют собой разломы, не сопровождающиеся полным отрывом материала, часто едва заметны при фронтальной съёмке, но становятся видимыми при отражённом свете или под определёнными углами. Выявление

трещин требует повышенной чувствительности модели и хорошей контрастности изображения.

Разрушения оболочки (полные разломы, оголение внутреннего содержимого) — наиболее грубый тип дефекта, при котором шоколадная или карамельная оболочка разрушена на значительной площади. Эти дефекты на поверхности легко визуализируются, сопровождаются появлением фрагментов на конвейере и могут нарушать работу упаковочного оборудования.

Визуальные характеристики каждого типа дефекта были учтены при формировании классов для аннотирования изображений и обучения нейросетевой модели. Такая классификация позволила повысить точность системы при сегментации объектов и адаптировать модель под реальные производственные условия. Кроме того, каждый из классов имеет потенциальную связь с конкретными причинами возникновения (удары, вибрация, отклонения по температуре), что открывает возможности для последующего анализа причин брака.

Методы реализации и архитектурные решения автоматизированной системы

В основе разрабатываемой автоматизированной системы контроля качества драже лежит модульный архитектурный подход, обеспечивающий интеграцию подсистем машинного зрения, цифрового моделирования, интеллектуального анализа данных и управления исполнительными механизмами. Центральным компонентом является система технического зрения, построенная на основе сверточной нейронной сети YOLOv8, предназначенной для обнаружения дефектов поверхности изделий в реальном времени. Обучение модели осуществлялось на комбинированном датасете, включающем реальные и синтетически сгенерированные

изображения даже с дефектами и без них. Для повышения устойчивости алгоритма к вариациям внешней среды (освещение, ориентация объекта, отражения) использовались методы аугментации и регуляризации данных, а также техника transfer learning с дообучением модели на специализированной выборке [9].

Визуальный модуль системы включает высокоскоростную промышленную камеру с возможностью тонкой настройки экспозиции и фильтрации шумов, а также блок локальной предобработки изображений, реализованный на базе графического процессора. Визуальные данные поступают в ядро системы, где происходит первичная сегментация и классификация изделий, после чего координаты дефектных объектов передаются на управляющий контроллер для активации исполнительных механизмов — сортировщиков и направляющих устройств. Передача данных осуществляется по локальной сети с использованием протокола OPC UA, обеспечивающего отказоустойчивую и масштабируемую интеграцию с существующими модулями управления.

Цифровое моделирование производственного процесса реализовано в отечественной платформе R-PRO, разработанной для создания интерактивных симуляционных моделей технологических линий. С её помощью создана параметризуемая модель участка сортировки и контроля качества даже представленная на рисунке 1, включая конвейер, камеру машинного зрения, модуль освещения и систему позиционирования. R-PRO позволила провести виртуальное тестирование различных конфигураций оборудования, протестировать сценарии с изменёнными условиями съёмки, а также спрогнозировать поведение системы в условиях повышенной загрузки. Особое внимание было уделено моделированию нестандартных ситуаций — частичной окклюзии объектов, наложения изделий друг на друга,

отражающих поверхностей и вибраций — с последующей корректировкой параметров визуального модуля на этапе внедрения.

В рамках архитектурного решения предусмотрен механизм адаптации системы к новым условиям без необходимости полной переобучения модели. Это реализовано за счёт создания интерфейса настройки ключевых параметров обработки изображений, калибровки камеры и обновления симуляционных сценариев в R-PRO. Предложенное решение обеспечивает не только высокую точность обнаружения дефектов, но и возможность масштабирования и адаптации под различные типы кондитерской продукции и условия конкретного производства.




Рис. 1. Цифровая симуляция линии контроля драже в R-PRO

В рамках архитектурного решения предусмотрен механизм адаптации системы к новым условиям без необходимости полной переобучения модели. Это реализовано за счёт создания интерфейса настройки ключевых

параметров обработки изображений, калибровки камеры и обновления симуляционных сценариев в R-PRO. Предложенное решение обеспечивает не только высокую точность обнаружения дефектов, но и возможность масштабирования и адаптации под различные типы кондитерской продукции и условия конкретного производства.

Формирование обучающего датасета является критическим этапом в разработке системы машинного зрения для контроля качества драже. Основная часть выборки была получена с использованием промышленной камеры, установленной на реальном или смоделированном участке производственной линии [10]. Изображения фиксировали драже в различных состояниях: без повреждений, с трещинами, сколами, деформациями и разрушениями оболочки. Для обеспечения высокого качества размеченных данных применялась ручная аннотация дефектных участков с помощью инструментария Labellmg и Roboflow. Отдельное внимание уделялось балансировке классов, чтобы исключить смещение модели в сторону нормально сформированных изделий, поскольку на практике дефекты встречаются относительно редко.

Для повышения универсальности и устойчивости нейросетевой модели часть датасета была дополнена синтетически сгенерированными изображениями. Эти изображения создавались на основе 3D-моделей драже с различной текстурой, цветом, освещением и ориентацией объектов. Моделирование проводилось в специализированных средах с возможностью управления параметрами освещения, тенью, отражением и положением камеры. Такой подход позволил существенно увеличить объем обучающей выборки, а также смоделировать труднодостижимые ситуации, например, частичное перекрытие объектов, блеск поверхности или слабое освещение. Пример одной из таких 3D-моделей представлен на рисунке 2.



Рис. 2. 3D-модель драже для генерации синтетических данных

Интеграция синтетических данных в тренировочную выборку позволила модели эффективнее обрабатывать визуальные артефакты, связанные с глянцевыми поверхностями, разной интенсивностью цвета и геометрическими искажениями изделий. Это обеспечило более высокую обобщающую способность алгоритма при последующем тестировании на реальных производственных изображениях.

Результаты исследования

Разработанная система машинного зрения была интегрирована в структуру цифровой модели производственной линии, смоделированной в R-PRO, а также протестирована на реальных изображениях, полученных в условиях, имитирующих промышленную эксплуатацию. Проведённые испытания позволили оценить эффективность работы нейросетевого модуля по обнаружению и классификации дефектов на поверхности драже в потоке.

Анализ показал, что система уверенно распознаёт как неповреждённые изделия, так и объекты с различными типами дефектов, включая сколы, трещины и частично разрушенные оболочки. При прохождении партии изделий по конвейеру, камера фиксирует поток в режиме реального времени, а обученная модель YOLOv8 производит локализацию каждого объекта и

моментально классифицирует его как «годный» или «дефектный». Объекты с дефектами подсвечиваются на изображении соответствующими рамками, и их координаты передаются на исполнительный механизм для сортировки. На тестовых изображениях, включающих как однородные (неповреждённые) изделия, так и смеси с дефектными образцами, точность классификации достигала 95,3%, при этом уровень ложноположительных результатов не превышал 4,2%.

Система также показала устойчивую работу при неравномерном освещении, небольших тенях, а также при частичном перекрытии изделий друг другом. Для случаев, где объекты находились на границе поля зрения или были ориентированы нехарактерным образом, цифровая симуляция позволила предварительно настроить параметры съёмки, минимизируя количество ложных срабатываний. Это подтвердило целесообразность предварительной калибровки и верификации системы на виртуальной модели до внедрения в реальное производство.

Отдельно следует отметить способность системы сохранять высокую скорость обработки потока: при частоте поступления до 50 изделий в секунду среднее время отклика составляло менее 40 мс на одно изображение. Это позволяет без ущерба производительности реализовать контроль качества в реальном времени, включая отклонение дефектных изделий и архивирование визуальных данных для последующего аудита.

Визуальные пример работы алгоритма представлен на рисунке 3. Модель успешно определяет дефектные экземпляры по признакам сколов, трещин и деформаций. Классы отображаются в режиме реального времени поверх каждого объекта на изображении, обеспечивая визуальную обратную связь и автоматическую передачу координат на исполнительные устройства для дальнейшей сортировки.




Рис. 3. Работа системы машинного зрения на партии с повреждёнными драже.

Полученные результаты подтверждают высокую эффективность предложенного решения как в плане точности, так и в аспекте технологической адаптивности. Система может быть масштабирована для работы с другими типами продукции и легко интегрируется в существующие линии благодаря модульной архитектуре.

Заключение

В ходе проведённого исследования разработана и апробирована автоматизированная система контроля качества драже, основанная на технологиях машинного зрения и цифрового моделирования. Применение нейросетевого алгоритма YOLOv8 позволило обеспечить высокую точность распознавания дефектов поверхности, включая сколы, трещины и разрушения оболочки, в условиях реального и виртуального производственного потока. Использование цифровой симуляции в среде R-PRO дало возможность предварительно оптимизировать параметры съёмки,

протестировать систему в различных сценариях и сократить затраты на наладку оборудования.

Формирование обучающего датасета с применением как реальных изображений, так и синтетически сгенерированных на основе 3D-моделей, позволило существенно повысить обобщающую способность системы и её устойчивость к внешним факторам. Результаты экспериментов подтвердили эффективность предложенного подхода: точность детекции превысила 95%, а производительность системы обеспечила возможность обработки потока продукции в реальном времени без снижения темпа производства.

Предложенное решение демонстрирует высокую прикладную значимость для пищевой промышленности, открывая перспективы масштабирования технологии на другие виды кондитерской продукции и применения в смежных отраслях. Полученные результаты могут быть использованы при проектировании интеллектуальных линий сортировки и упаковки, а также в рамках создания цифровых двойников технологических процессов. В дальнейшем планируется расширение функционала системы за счёт интеграции модуля предиктивной аналитики и автоматического обучения на новых данных.

Литература

1. Жакова К. И., Миронова Н. П. Современные тенденции развития технологий пищевых производств //Пищевая промышленность: наука и технологии. – 2022. – Т. 15. – №. 3. – С. 6-12.
2. Киселева Ю. С., Дусаева Х. Б. Особенности технологии производства драже //Университетский комплекс как региональный центр образования, науки и культуры. – 2021. – С. 1831-1833.
3. Винницкая В.Ф., Попова Е.И., Богданова Ю.С., Данилин С.И. Способ производства фруктовых драже с медом для функционального, спортивного и

школьного питания //Инновационные проекты Мичуринского государственного аграрного университета. – 2021. – С. 103.

4. Гайдаренко А. С., Копалин А. С. Анализ методов распознавания образов с помощью искусственного интеллекта //современные научные знания. – 2023. – С. 56-58.

5. Nosratabadi S, Ardabili S, Lakner Z, Mako C, Mosavi A. Prediction of food production using machine learning algorithms of multilayer perceptron and ANFIS //Agriculture. – 2021. – V. 11. – №. 5. – P. 408.

6. Zhu L., Spachos P., Pensini E, Plataniotis K. N. Deep learning and machine vision for food processing: A survey //Current Research in Food Science. – 2021. – V. 4. – P. 233-249.

7. Аднодворцев А.М., Благовещенский И.Г., Благовещенский В.Г., Носенко А.С., Веселов М.В., Нгонганг Р.Д. Создание интеллектуальных систем принятия решений на базе технологии свёрточных нейронных сетей //Фабрика будущего: переход к передовым цифровым, интеллектуальным производственным технологиям, роботизированным системам для отраслей пищевой промышленности. – 2022. – С. 25-32.

8. Раковец В. В., Логунова Н. Ю. Моделирование производственных процессов предприятий пищевой промышленности //Сборник научных трудов Международного научно-технического Симпозиума «Экономические механизмы стратегического управления развитием промышленности» III Международного Косыгинского Форума «Современные задачи инженерных наук». – 2021. – С. 107-112.

9. Игнатьева О. В., Сокирка А. Д., Журавлев Д. С. Применение методов машинного зрения на встраиваемых системах // Инженерный вестник Дона. – 2024. – № 1. URL: ivdon.ru/ru/magazine/archive/n1y2024/8918

10. Лебедев Б. К., Лебедев О. Б., Черкасов Р. И. Использование нейронных сетей для решения задач компьютерного зрения // Инженерный вестник Дона. – 2025. – № 2. URL: ivdon.ru/ru/magazine/archive/n2y2025/9870

References

1. Zhakova K. I., Mironova N. P. Pishhevaya promy'shlennost': nauka i texnologii. 2022. V. 15. №. 3. pp. 6-12.
2. Kiseleva Yu. S., Dusaeva X. B. Universitetskij kompleks kak regional'ny'j centr obrazovaniya, nauki i kul'tury'. 2021. pp.1831-1833.
3. Vinniczkaia V.F., Popova E.I., Bogdanova Yu.S., Danilin S.I. Innovacionny'e proekty' Michurinskogo gosudarstvennogo agrarnogo universiteta. 2021. p. 103.
4. Gajdarenko A. S., Kopalin A. S. Sovremenny'e nauchny'e znaniya. 2023. pp. 56-58.
5. Nosratabadi S, Ardabili S, Lakner Z, Mako C, Mosavi A. Agriculture. – 2021. V. 11. №. 5. p. 408.
6. Zhu L., Spachos P., Pensini E, Plataniotis K. N. Deep Current Research in Food Science. 2021. V. 4. pp. 233-249.
7. Adnodvorcev A.M., Blagoveshhenskij I.G., Blagoveshhenskij V.G., Nosenko A.S., Veselov M.V., Ngongang R.D. Fabrika budushhego: perexod k peredovy'm cifrovym, intellektual'ny'm proizvodstvenny'm texnologiyam, robotizirovanny'm sistemam dlya otraslej pishhevoj promy'shlennosti. 2022. pp. 25-32.
8. Rakovecz V. V., Logunova N. Yu. Sbornik nauchny'x trudov Mezhdunarodnogo nauchno texnicheskogo Simpoziuma «E'konomicheskie mexanizmy' strategicheskogo upravleniya razvitiem promy'shlennosti» III Mezhdunarodnogo Kosy'ginskogo Forumа «Sovremenny'e zadachi inzhenerny'x nauk». 2021. pp. 107-112.



9. Ignat`eva O. V., Sokirka A. D., Zhuravlev D. S. Inzhenernyj vestnik Dona. 2024. № 1. URL: ivdon.ru/ru/magazine/archive/n1y2024/8918
10. Lebedev B. K., Lebedev O. B., Cherkasov R. I. Inzhenernyj vestnik Dona. 2025. № 2. URL: ivdon.ru/ru/magazine/archive/n2y2025/9870.

Дата поступления: 3.07.2025

Дата публикации: 25.08.2025