

УДК 631.362:634.1

4.3.1. Технологии машины и оборудование для агропромышленного комплекса

РАСПОЗНАВАНИЕ И ПОДСЧЕТ ПЛОДОВ ЯБЛОНИ С ПРИЗНАКАМИ ГНИЛИ НА СОРТИРОВОЧНОЙ ЛИНИИ С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВОЙ МОДЕЛИ YOLO26

Кутырёв Алексей Игоревич
кандидат технических наук, заведующий лабораторией интеллектуальных цифровых систем мониторинга, диагностики и управления процессами в сельскохозяйственном производстве
SPIN-код: 9793-5074
AuthorID: 822733
Web of Science ResearcherID: I-3699-2018
Scopus ID: 57206770758
ORCID: 0000-0001-7643-775X
E-mail: alexeykutyrev@gmail.com
Федеральный научный агроинженерный центр ВИМ, Москва, Россия

Потапенков Никита Александрович
магистрант, инженер лаборатории интеллектуальных цифровых систем мониторинга, диагностики и управления процессами в сельскохозяйственном производстве
SPIN-код: 6112-4416
AuthorID: 1303101
ORCID: 0009-0006-3713-205X
E-mail: potapson64@yandex.ru
Федеральный научный агроинженерный центр ВИМ, Москва, Россия

Оптические искажения, возникающие при промышленной мойке (гидрообработки) плодов яблони, снижают эффективность автоматического распознавания гнили. Цель исследований – разработка и валидация метода автоматического распознавания плодов яблони с признаками гнили и алгоритма их подсчёта после этапа гидрообработки в режиме реального времени. Для распознавания плодов яблони с признаками гнили использована нейросетевая архитектура YOLO26, обученная методом трансферного обучения с использованием модели, предобученной на наборе данных COCO; датасет включал 2514 размеченных изображений плодов после мойки (класс «rottenApple»). Проведён сравнительный анализ моделей YOLO26n/s/m/l/x по метрикам Precision, Recall, mAP50 и скорости инференса. Для учёта количества распознанных плодов разработан алгоритм, фиксирующий пересечения геометрических центров ограничивающих прямоугольников со статической контрольной зоной. Установлено, что модель YOLO26s обеспечивает оптимальный баланс точности и

UDC 631.362:634.1

4.3.1. Technologies, machinery and equipment for the agro-industrial complex

RECOGNITION AND COUNTING OF APPLE FRUITS WITH SIGNS OF ROT ON A SORTING LINE USING YOLO26

Kutyrev Alexey Igorevich
Candidate of technical sciences, Head of the Laboratory of Intelligent Digital Systems for Monitoring, Diagnostics and Process Control in Agricultural Production
RSCI SPIN-code: 9793-5074
AuthorID: 822733
Web of Science ResearcherID: I-3699-2018
Scopus ID: 57206770758
ORCID: 0000-0001-7643-775X
E-mail: alexeykutyrev@gmail.com
Federal Scientific Agroengineering Center VIM, Moscow, Russia

Potapenkov Nikita Alexandrovich
Master's student, Engineer of the Laboratory of Intelligent Digital Systems for Monitoring, Diagnostics and Process Control in Agricultural Production
RSCI SPIN-code: 6112-4416
AuthorID: 1303101
ORCID: 0009-0006-3713-205X
E-mail: potapson64@yandex.ru
Federal Scientific Agroengineering Center VIM, Moscow, Russia

Optical distortions arising during industrial washing (hydrotreatment) of apple fruits reduce the effectiveness of automatic rot recognition. The aim of the research is to develop and validate a method for automatic recognition of apple fruits with signs of rot and an algorithm for counting them after the hydrotreatment stage in real time. To recognize apple fruits with signs of rot, the YOLO26 neural network architecture was used, trained by the transfer learning method using a model pre-trained on the COCO dataset; the dataset included 2,514 labeled images of fruits after washing (class "rottenApple"). A comparative analysis of YOLO26n/s/m/l/x models was carried out using the metrics Precision, Recall, mAP50, and inference speed. To count the number of recognized fruits, an algorithm was developed that records the intersections of the geometric centers of bounding boxes with a static control zone. It was found that the YOLO26s model provides an optimal balance of accuracy and performance: Precision = 0.931, Recall = 0.936, mAP50 = 0.979 with a processing time of 4.1 ms per frame, which allows processing a video stream at a frequency of more than

производительности: Precision = 0,931, Recall = 0,936, mAP50 = 0,979 при времени обработки 4,1 мс на кадр, что позволяет обрабатывать видеопоток с частотой более 240 кадров/с. Разработанный метод может быть интегрирован в существующие сортировочные линии для повышения качества отбраковки дефектной продукции

240 frames per second. The developed method can be integrated into existing sorting lines to improve the quality of defective product rejection

Ключевые слова: КОМПЬЮТЕРНОЕ ЗРЕНИЕ, РАСПОЗНАВАНИЕ ПЛОДОВ ЯБЛОНИ, YOLO26, ПОДСЧЁТ ОБЪЕКТОВ, КОНТРОЛЬНАЯ ЗОНА, СОРТИРОВОЧНАЯ ЛИНИЯ, РЕАЛЬНОЕ ВРЕМЯ

Keywords: COMPUTER VISION, APPLE FRUIT RECOGNITION, YOLO26, OBJECT COUNTING, CONTROL ZONE, SORTING LINE, REAL TIME

<http://dx.doi.org/10.21515/1990-4665-217-036>

Введение.

Для семечковых культур, в частности яблони, этап калибровки и отбраковки плодов определяет качество конечного продукта и его соответствие товарным стандартам [1,2]. Особое значение приобретает выявление плодов с признаками гнилостных поражений, так как их присутствие в товарной партии не только снижает ее стоимость, но и может привести к поражению всей партии продукции при последующем хранении [3].

Традиционные методы визуального контроля, осуществляемого человеком-оператором на сортировочных линиях, характеризуются высокой трудоемкостью, субъективностью и быстрым утомлением персонала, что приводит к снижению точности сортировки при увеличении скорости конвейера [4]. В связи с этим перспективным направлением является использование систем компьютерного зрения на базе методов глубокого обучения, которые позволяют автоматизировать процесс распознавания дефектов в режиме реального времени [5, 6]. Архитектуры сверточных нейронных сетей, такие как YOLO (You Only Look Once), показывают оптимальный баланс между точностью и скоростью обработки видеопотока [7,8].

Однако применительно к условиям промышленной переработки яблок существует ряд нерешенных проблем. Во-первых, специфика

производственной среды, включающая этап гидрообработки (мойки), приводит к изменению оптических свойств поверхности плода (наличие капель, бликов, повышенная влажность), что может негативно сказываться на обобщающей способности моделей. Во-вторых, большинство существующих решений ориентировано на распознавание дефектов, но не предлагают встроенных механизмов точного количественного учета некондиционной продукции непосредственно в процессе движения конвейера, что необходимо для оперативного управления исполнительными устройствами линии сортировки и обеспечения обратной связи в автоматизированной системе управления технологическим процессом.

Цель исследования – разработка и валидация метода автоматического распознавания плодов яблони с признаками гнили и алгоритма их подсчёта после этапа гидрообработки в режиме реального времени.

Материалы и методы. Сформирован набор изображений плодов яблони на промышленной сортировочной линии. Исходный видеопоток фиксировался с помощью камеры DJI Action 5 Pro, установленной стационарно над конвейерной лентой. Съёмка велась с разрешением 1920×1080 пикселей при частоте 60 кадров в секунду.

Для последующего анализа из видеозаписи были отобраны отдельные кадры, которые затем прошли этап ручного аннотирования (разметки). Разметка выполнялась с использованием облачной платформы Roboflow, где для каждого плода вручную определялась ограничивающая прямоугольная область (bounding box) с присвоением класса «rottenApple» для плодов с видимыми признаками гнили (рисунок 1). Всего было размечено 2514 исходных изображений.

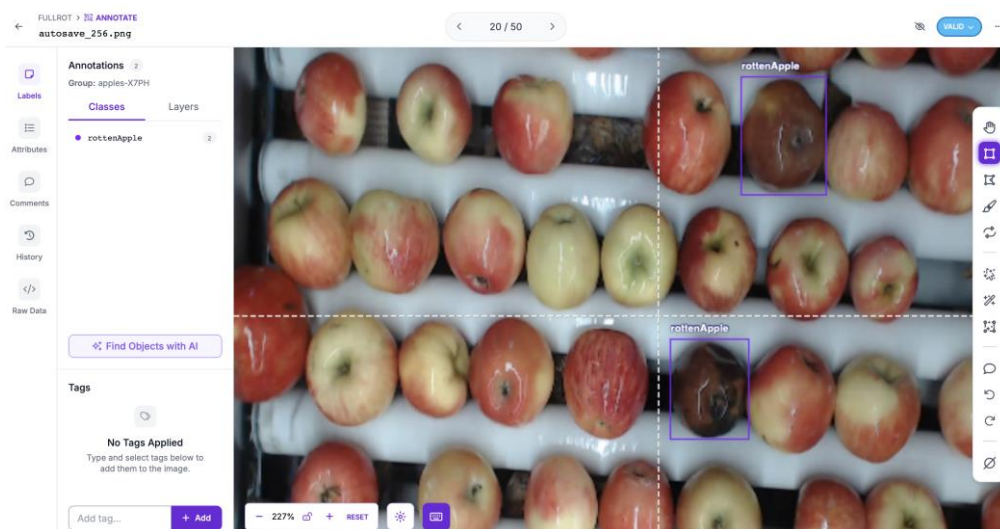


Рисунок 1 – Процесс разметки изображений в облачной платформе Roboflow

Сформированный датасет был разделён на три выборки: обучающую, которая использовалась для тренировки модели, валидационную - для контроля процесса обучения и подбора гиперпараметров, и тестовую - для финальной оценки качества работы модели. Соотношение выборок составило 70%, 15% и 15% соответственно.

Для обучения модели нейронной сети использована архитектура YOLO26. Обучение модели проводилось методом трансферного обучения (transfer learning) с использованием предварительно обученной на наборе данных COCO модели. Гиперпараметры обучения включали размер входного изображения 640x640 пикселей, общее количество эпох обучения - 1000. Для предотвращения переобучения применялся механизм ранней остановки (early stopping) при отсутствии улучшений метрик на валидационной выборке в течение 40 эпох обучения.

Обучение моделей YOLO26 проводилось с использованием среды Google Colab, предоставляющей удаленный доступ к графическому процессору NVIDIA Tesla T4. Виртуальная машина обеспечивала необходимый объем видеопамяти (16 ГБ) и дискового пространства для обработки датасета и хранения весов моделей.

Оценка эффективности обученной модели производилась по стандартному набору метрик для задач распознавания объектов. Точность (Precision) определялась как доля верно обнаруженных гнилых плодов среди всех объектов, отнесённых моделью к этому классу (формула 1).

$$\text{Precision} = \frac{TP}{TP+FP} \quad (1)$$

Полнота (Recall) характеризует долю верно распознанных гнилых плодов от их общего количества в выборке (формула 2).

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2)$$

где TP (True Positive) – количество верно классифицированных положительных случаев (плоды яблони с гнилью, верно распознанные как гнилые), FP (False Positive) – количество ложноположительных случаев (плоды яблони без признака гнили, ошибочно классифицированные как гнилые), FN (False Negative) – количество ложноотрицательных случаев (гнилые плоды яблони, ошибочно определённые как не имеющие признаков гнили).

Метрика Mean Average Precision (mAP) использована для расчета средней площади под кривой точности-полноты (Precision-Recall) (формула 3).

$$mAP_{\text{Box}} = \frac{1}{n} \sum_{i=1}^N AP_{\text{Box}/\text{Mask},i} \quad (3)$$

где N – количество классов объектов, $AP_{\text{Box}/\text{Mask},i}$ – площадь под кривой точности-полноты (Precision-Recall curve) для каждого класса i .

Метрика mAP учитывает как точность, так и полноту при обнаружении объектов, позволяет определить производительность модели. Чем выше значение mAP, тем более точно модель распознает объекты различных классов на изображениях [9-11].

Результаты и обсуждение. Проведённое обучение моделей нейронных сетей семейства YOLO26 (n, s, m, l, x) позволило выявить закономерность: с увеличением архитектурной сложности наблюдается

устойчивый рост метрик распознавания. Для модели YOLO26n получены следующие метрики: Precision = 0,909, Recall = 0,932, mAP50 = 0,977; скорость обработки составила 2,8 мс на кадр. По мере перехода к моделям с большим количеством параметров, показатели улучшаются, достигая максимума. У модели YOLO26x метрика Precision составила 0,949, Recall 0,968 и mAP50 0,990. Этот прирост качества сопровождается существенным увеличением вычислительных затрат, время обработки одного кадра возрастает с 2,8 мс у YOLO26n до 19,6 мс у YOLO26x (таблица 1).

Модель	Метрика точности, распознавания ограничивающих рамок (Precision Box)	Метрика полноты, распознавания ограничивающих рамок (Recall Box)	Средняя точность, распознавания ограничивающих рамок (mAP50 Box)	Скорость обработки одного кадра, мс (inference)
YOLO26n	0,909	0,932	0,977	2,8
YOLO26s	0,931	0,936	0,979	4,1
YOLO26m	0,932	0,941	0,980	10,1
YOLO26l	0,935	0,953	0,985	13,6
YOLO26x	0,949	0,968	0,990	19,6

Таблица 1 – Результаты вычисления метрик модели YOLO26 при распознавании плодов яблони с признаками гнили

Пример распознавания плодов яблони с признаками гнили с помощью модели YOLO26s представлен на рисунке 2.




Рисунок 2 – Пример распознавания плодов яблони с признаками гнили, модель YOLO26s

График изменения метрики Precision показывает различия в динамике обучения моделей (рисунок 3). На начальном этапе (0-20 итераций) все пять моделей показывают рост точности, однако архитектуры с большим числом параметров YOLO26l и YOLO26x характеризуются несколько более высоким темпом роста, что свидетельствует об их способности быстрее обучаться на начальных этапах благодаря большему числу параметров. В интервале 20-60 итераций модели с меньшим числом параметров YOLO26n и YOLO26s входят в режим умеренных колебаний с амплитудой изменения метрик 0,02-0,03, тогда как архитектурно более сложные модели показывают более плавную стабилизацию метрик с меньшей вариативностью. После 60-й итерации все пять моделей выходят на плато. К концу обучения амплитуда колебаний для всех моделей минимизируется, дальнейший рост метрики прекращается.

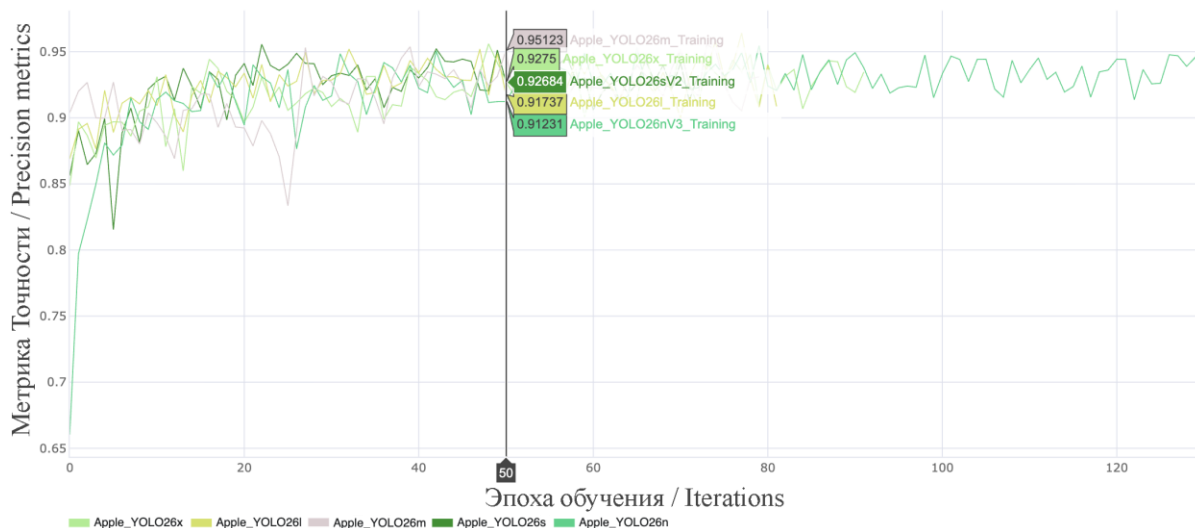


Рисунок 3 – Зависимость метрики Precision от количества эпох обучения

Кривые полноты Recall (рисунок 4) имеют более сглаженный характер для всех пяти архитектур на протяжении обучения. Начальный этап (0-20 итераций) характеризуется ростом метрик всех моделей, причём различия между архитектурами на этом этапе минимальны. В диапазоне 20-80 итераций модели с большим числом параметров YOLO26l и YOLO26x показывают более высокий темп прироста метрики Recall. На завершающем этапе (80-120 итераций) все пять моделей выходят на плато. Отсутствие спада полноты на поздних итерациях для всех моделей подтверждает сохранение обобщающей способности без признаков переобучения.




Рисунок 4 – Зависимость метрики Recall от количества эпох обучения

Интегральная метрика mAP50(B) наиболее наглядно отражает различия в эффективности обучения пяти архитектур (рисунок 5). На начальном этапе (0-40 итераций) наблюдается наиболее интенсивный рост для всех моделей, темп прироста прямо пропорционален размеру архитектуры. В интервале 40-80 итераций кривые выходят в режим сходимости, при этом архитектуры с большим количеством параметров показывают более раннюю стабилизацию и меньшую амплитуду последующих колебаний метрик. После 80-й итерации все пять архитектур показывают устойчивое плато.

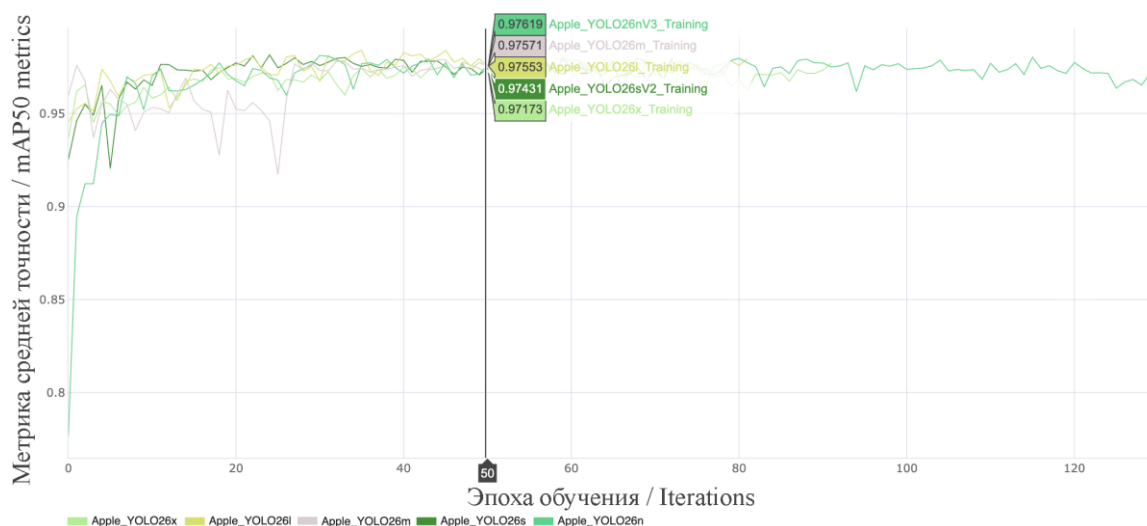


Рисунок 5 – Зависимость метрики Recall (B) от количества эпох обучения

Разрабатываемая система компьютерного зрения предназначена для работы в режиме реального времени на сортировочной линии, основным требованием является не только высокая точность распознавания гнили, но и минимальная задержка при обработке видеопотока. Использование модели YOLO26x, несмотря на наилучшие показатели метрик, нецелесообразно из-за высокой вычислительной нагрузки, которая приведёт к снижению частоты кадров и к пропуску объектов. Модели YOLO26m и YOLO26l также характеризуются избыточными временными затратами. Модель YOLO26n, обладая наивысшей скоростью обработки

кадров, уступает YOLO26s по метрикам полноты и точности. Наиболее оптимальной моделью для поставленной задачи является YOLO26s. Модель обеспечивает наилучший баланс между точностью ($mAP50 = 0,979$, Precision = 0,931, Recall = 0,936) и скоростью обработки кадров (4,1 мс на кадр), что соответствует требованиям к системам технического зрения, работающим в режиме реального времени. Достигнутая производительность позволяет обрабатывать видеопоток с частотой более 240 кадров в секунду.

Для точного учёта количества плодов, прошедших через зону контроля сортировочной линии, разработан алгоритм, основанный на анализе пересечений геометрических центров ограничивающих прямоугольников обнаруженных объектов со статической контрольной областью (рисунок 6).

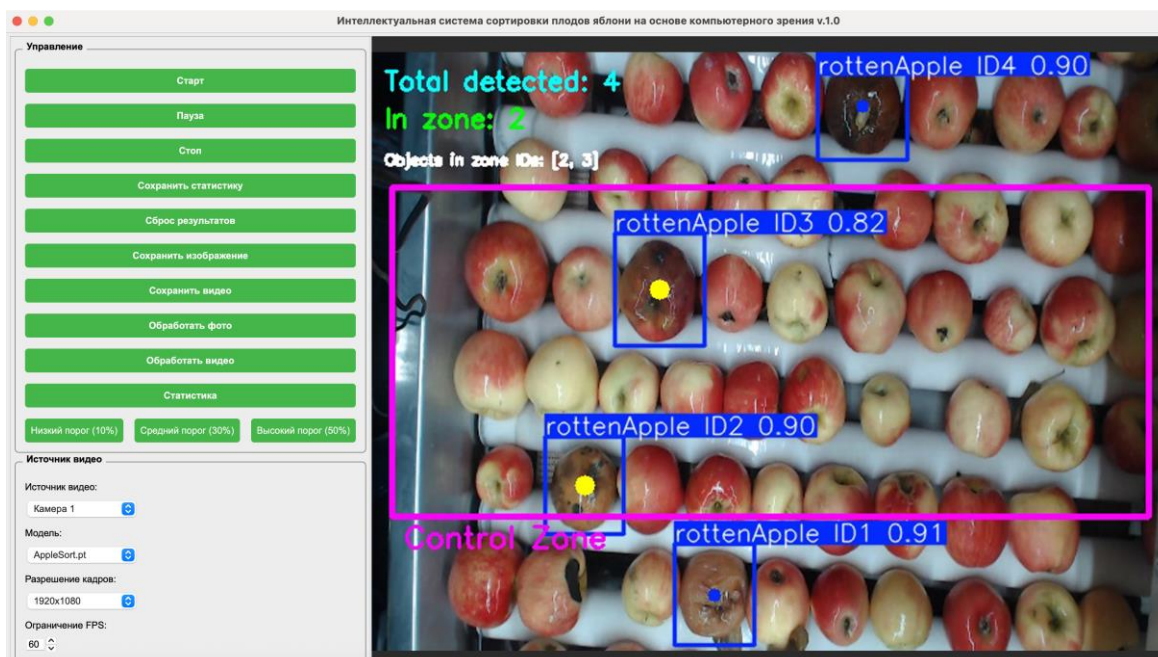


Рисунок 6 – Пример работы алгоритма для подсчёта плодов яблоки

Данный алгоритм отличается от классических методов множественного отслеживания (трекинга) объектов, которые строят полные траектории движения объектов и требуют решения сложной задачи ассоциации данных между кадрами на всём протяжении

нахождения объекта в поле зрения камеры. Разработанный алгоритм фокусируется исключительно на дискретных событиях входа и выхода плода яблони через ограничивающую рамку, что позволяет минимизировать вычислительные затраты при сохранении высокой точности учёта, необходимой для работы в режиме реального времени [8].

Основой алгоритма является задание в кадре статической прямоугольной зоны подсчёта (формула 4).

$$Z = \text{defineZone}(x_{\text{start}}, y_{\text{start}}, \omega_{\text{rel}}, h_{\text{rel}}) \quad (4)$$

где $x_{\text{start}}, y_{\text{start}}, \omega_{\text{rel}}, h_{\text{rel}}$ – относительные координаты и размеры зоны подсчёта.

Положение и размеры этой зоны определяются в относительных координатах, что обеспечивает инвариантность к разрешению входного видеопотока и позволяет настраивать систему под различные условия съёмки (формула 5).

$$\begin{aligned} X_{\text{abs}} &= x_{\text{start}} \times \text{frame_width} \\ Y_{\text{abs}} &= y_{\text{start}} \times \text{frame_height} \\ W_{\text{abs}} &= \omega_{\text{rel}} \times \text{frame_width} \\ H_{\text{abs}} &= h_{\text{rel}} \times \text{frame_height} \end{aligned} \quad (5)$$

Координаты центра определяются как целочисленные значения полу суммы минимальных и максимальных координат ограничивающего прямоугольника по осям абсцисс и ординат соответственно (формула 6).

$$C(t) = \left(\left\lfloor \frac{x_{\text{min}} + x_{\text{max}}}{2} \right\rfloor, \left\lfloor \frac{y_{\text{min}} + y_{\text{max}}}{2} \right\rfloor \right) \quad (6)$$

где (x_1, x_2) – координаты левого верхнего угла прямоугольника, (y_1, y_2) – координаты правого нижнего угла, $\lfloor \cdot \rfloor$ – операция целочисленного деления.

Система фиксирует событие «вход» в том случае, если центр объекта, отсутствовавший внутри зоны на предыдущем кадре, оказывается внутри неё на текущем кадре (формула 7).

$$E_{\text{in}}(\text{id}, t) = 1 \leftrightarrow (\text{id} \notin Z(t-1)) \wedge (\text{id} \in Z(t)) \quad (7)$$

Обратное событие («выход») регистрируется при переходе центра объекта из внутренней области зоны во внешнюю (формула 8).

$$E_{out}(id, t) = 1 \leftrightarrow (id \in Z(t - 1)) \wedge (id \notin Z(t)) \quad (8)$$

Данный алгоритм не требует сопоставления объектов между кадрами на всём пути их движения, а учитывает факт наличия или отсутствия конкретного идентификатора (ID) внутри зоны в смежных кадрах. Для работы алгоритма подсчёта достаточно фиксации этих идентификаторов лишь в моменты пересечения границ контрольной области.

Итоговое количество плодов, прошедших через зону контроля за время работы системы, вычисляется как полусумма всех зарегистрированных событий входа и выхода (формула 9).

$$N_{total} = \left\lfloor \frac{count_{in} + count_{out}}{2} \right\rfloor \quad (9)$$

Формула обусловлена тем, что каждый объект, движущийся через контрольную зону, неизбежно пересекает её границу дважды, при входе, затем при выходе.

Разработанный алгоритм обладает рядом преимуществ для практического применения. Минимальные вычислительные затраты позволяют использовать его на оборудовании с ограниченными вычислительными ресурсами без снижения частоты обработки кадров. Алгоритм устойчив к кратковременным потерям объекта, поскольку учитывается только факт пересечения границы, а не непрерывность траектории. Простота реализации и отсутствие необходимости в процедурах ассоциации данных обеспечивают высокую надёжность работы в условиях производственного процесса.

Выводы. В ходе исследований разработан и валидирован метод автоматического распознавания и алгоритм подсчёта плодов яблони с признаками гнили на конвейерной линии после этапа гидрообработки (мойки) в режиме реального времени. Сравнительный анализ пяти архитектур семейства YOLO26 различной размерности выявил

зависимость между архитектурной сложностью модели, точностью распознавания и скоростью обработки. Оптимальной конфигурацией для решения поставленной задачи признана модель YOLO26s, обеспечивающая наилучший баланс между точностью и производительностью.

Для учёта плодов яблони, прошедших через зону контроля, разработан алгоритм, основанный на фиксации пересечений геометрических центров ограничивающих прямоугольников распознанных объектов со статической контрольной областью. Алгоритм обеспечивает высокую точность подсчета плодов яблони при минимальных вычислительных затратах.

Список использованной литературы

1. Baneh N., Navid H., Kafashan J., Fouladi H., Gonzales-Barrón U. Development and Evaluation of a Small-Scale Apple Sorting Machine Equipped with a Smart Vision System // *AgriEngineering*. 2023; 5(1):473-487.
2. Khort D.O., Kuttyrev A., Smirnov I., Andriyanov N., Filippov R., Chilikin A., Astashev M.E., Molkova E.A., Sarimov R.M., Matveeva T.A., Gudkov S. Enhancing sustainable automated fruit sorting: hyperspectral analysis and machine learning algorithms // *Sustainability*. 2024. Т. 16. № 22. С. 10084.
3. Lee J-H., Vo H-T., Kwon G-J., Kim H-G., Kim J-Y. Multi-Camera-Based Sorting System for Surface Defects of Apples. *Sensors* // 2023; 23(8):3968.
4. Xu B., Cui X., Ji W., Yuan H., Wang J. Apple Grading Method Design and Implementation for Automatic Grader Based on Improved YOLOv5 // *Agriculture*. 2023; 13(1):124.
5. Rojas Santelices I., Cano S., Moreira F., Peña Fritz Á. Artificial Vision Systems for Fruit Inspection and Classification: Systematic Literature Review // *Sensors*. 2025; 25(5):1524.
6. Кутырёв А.И., Потапенков Н.А. Программа компьютерного зрения для распознавания, классификации и сегментации плодов яблони на линии сортировки с использованием алгоритмов машинного обучения // Свидетельство о регистрации программы для ЭВМ RU 2025682457, 22.08.2025. Заявка № 2025681419 от 10.07.2025.
7. Кутырёв А.И. Распознавание и классификация болезней листьев яблони на основе анализа их изображений моделями сверточных нейронных сетей (CNN) // *Вестник Ульяновской государственной сельскохозяйственной академии*. 2023. № 3 (63). С. 215-223.
8. Потапенков Н.А., Кутырёв А.И. Разработка модели свёрточной нейронной сети для распознавания и классификации плодов яблони на линии сортировки // В сборнике: *Инновационные технологии в агропромышленном комплексе в условиях цифровой*

трансформации. Материалы Международной научно-практической конференции. Волгоград, 2025. С. 225-231.

9. Кутырёв А.И., Смирнов И.Г., Андриянов Н.А. Сравнительный анализ моделей нейронных сетей для распознавания плодов яблони на кроне дерева // Садоводство и виноградарство. 2023. № 5. С. 56-63.

10. Хорт Д.О., Кутырев А.И., Смирнов И.Г., Филиппов Р.А., Вершинин Р.В. Разработка алгоритмов системы распознавания ягод земляники садовой при роботизированном сборе // Электротехнологии и электрооборудование в АПК. 2020. Т. 67. № 1 (38). С. 133-141.

11. Kutyrev A.I., Andriyanov N.A. Apple flower recognition using convolutional neural networks with transfer learning and data augmentation technique // E3S Web of Conferences. International Conference on Advances in Agrobusiness and Biotechnology Research (ABR 2024). EDP Sciences, 2024. С. 01006.

References

1. Baneh N., Navid H., Kafashan J., Fouladi H., Gonzales-Barrón U. Development and Evaluation of a Small-Scale Apple Sorting Machine Equipped with a Smart Vision System // AgriEngineering. 2023; 5(1):473-487.

2. Khort D.O., Kutyrev A., Smirnov I., Andriyanov N., Filippov R., Chilikin A., Astashev M.E., Molkova E.A., Sarimov R.M., Matveeva T.A., Gudkov S. Enhancing sustainable automated fruit sorting: hyperspectral analysis and machine learning algorithms // Sustainability. 2024. Т. 16. № 22. С. 10084.

3. Lee J-H., Vo H-T., Kwon G-J., Kim H-G., Kim J-Y. Multi-Camera-Based Sorting System for Surface Defects of Apples // Sensors. 2023; 23(8):3968.

4. Xu B., Cui X., Ji W., Yuan H., Wang J. Apple Grading Method Design and Implementation for Automatic Grader Based on Improved YOLOv5 // Agriculture. 2023; 13(1):124.

5. Rojas Santelices I., Cano S., Moreira F., Peña Fritz Á. Artificial Vision Systems for Fruit Inspection and Classification: Systematic Literature Review // Sensors. 2025; 25(5):1524.

6. Kutyryov A.I., Potapenkov N.A. Programma komp'yuternogo zreniya dlya raspoznavaniya, klassifikatsii i segmentatsii plodov yablони na linii sortirovki s ispol'zovaniem algoritmov mashinnogo obucheniya // Svidetel'stvo o registratsii programmy dlya EVM RU 2025682457, 22.08.2025. Zayavka № 2025681419 ot 10.07.2025.

7. Kutyryov A.I. Raspoznavanie i klassifikatsiya boleznej list'ev yablони na osnove analiza ih izobrazhenij modelyami svertochnykh nejronnykh setej (CNN) // Vestnik Ul'yanskoj gosudarstvennoj sel'skohozyajstvennoj akademii. 2023. № 3 (63). С. 215-223.

8. Potapenkov N.A., Kutyryov A.I. Razrabotka modeli svyertochnoj nejronnoj seti dlya raspoznavaniya i klassifikatsii plodov yablони na linii sortirovki // V sbornike: Innovacionnye tekhnologii v agropromyshlennom komplekse v usloviyah cifrovoj transformatsii. Materialy Mezhdunarodnoj nauchno-prakticheskoj konferentsii. Volgograd, 2025. С. 225-231.

9. Kutyryov A.I., Smirnov I.G., Andriyanov N.A. Cravnitel'nyj analiz modelej nejronnykh setej dlya raspoznavaniya plodov yablони na kрone dereva // Sadovodstvo i vinogradarstvo. 2023. № 5. С. 56-63.

10. Hort D.O., Kutyrev A.I., Smirnov I.G., Filippov R.A., Vershinin R.V. Razrabotka algoritmov sistemy raspoznavaniya yagod zemlyaniki sadovoj pri robotizirovannom sbore // Elektrotekhnologii i elektrooborudovanie v APK. 2020. Т. 67. № 1 (38). С. 133-141.

11. Kutyrev A.I., Andriyanov N.A. Apple flower recognition using convolutional neural networks with transfer learning and data augmentation technique // E3S Web of Conferences.

International Conference on Advances in Agrobusiness and Biotechnology Research (ABR 2024). EDP Sciences, 2024. С. 01006.