

УДК 631.362:634.1

4.3.1 Технологии машины и оборудование для агропромышленного комплекса.

СЕГМЕНТАЦИЯ И КЛАССИФИКАЦИЯ ПЛОДОВ ЯБЛОНИ И ЛИСТЬЕВ НА СОРТИРОВОЧНОЙ ЛИНИИ С ПРИМЕНЕНИЕМ МОДЕЛИ YOLO26-SEG ДЛЯ АВТОМАТИЗАЦИИ КОНТРОЛЯ КАЧЕСТВА

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

Применение систем технического зрения на основе глубоких нейронных сетей повышает объективность контроля качества сортировки, однако листва и механически повреждённые плоды в сортируемом потоке создают дополнительные сложности для распознавания.

Целью исследований является разработка и валидация метода автоматического распознавания, сегментации и классификации некондиционных плодов яблони и листьев на сортировочной линии с использованием нейросетевой модели YOLO26-seg. Исследование выполнялось на датасете из 1171 изображения, размеченном с помощью платформы Roboflow и модели Segment Anything 3 (SAM 3) с последующей экспертной коррекцией. Обучение пяти архитектур семейства YOLO26-seg (n, s, m, l, x) проводилось методом трансферного обучения с аугментацией данных. Оценка качества осуществлялась по метрикам Precision, Recall и mAP50, а производительность

UDC 631.362:634.1

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

SEGMENTATION AND CLASSIFICATION OF APPLE FRUITS AND LEAVES ON A SORTING LINE USING THE YOLO26-SEG MODEL FOR QUALITY CONTROL AUTOMATION

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

The use of computer vision systems based on deep neural networks increases the objectivity of quality control during sorting, however, foliage and mechanically damaged fruits in the sorted flow create additional difficulties for recognition. The aim of the research is to develop and validate a method for automatic recognition, segmentation, and classification of substandard apple fruits and leaves on a sorting line using the YOLO26-seg neural network model. The study was carried out on a dataset of 1171 images, annotated using the Roboflow platform and the Segment Anything 3 (SAM 3) model, followed by expert correction. Training of five architectures of the YOLO26-seg family (n, s, m, l, x) was conducted using transfer learning with data augmentation. Quality assessment was performed using the Precision, Recall, and mAP50 metrics, and performance was analyzed based on frame processing time. It was found that increasing the architectural complexity of the models improves segmentation accuracy. All models

анализировалась по времени обработки кадра. Установлено, что увеличение архитектурной сложности моделей повышает точность сегментации. Все модели обеспечивают обработку видеопотока с частотой более 60 кадров/с. Оптимальный баланс между точностью и скоростью достигнут на модели YOLO26s-seg (104 кадра/с, mAP50 = 0,712), которая может быть рекомендована для внедрения в производственный процесс. Полученные результаты подтверждают эффективность предложенного метода для автоматизации контроля качества при сортировке плодов яблони

Ключевые слова: КОМПЬЮТЕРНОЕ ЗРЕНИЕ, СЕГМЕНТАЦИЯ ИЗОБРАЖЕНИЙ, YOLO26-SEG, ПЛОДЫ ЯБЛОНИ, ЛИСТЬЯ ЯБЛОНИ, ГНИЛЬ ПЛОДОВ, СОРТИРОВОЧНАЯ ЛИНИЯ, РЕАЛЬНОЕ ВРЕМЯ, МАШИННОЕ ОБУЧЕНИЕ, ТРАНСФЕРНОЕ ОБУЧЕНИЕ

provide video stream processing at a rate exceeding 60 frames per second. An optimal balance between accuracy and speed was achieved with the YOLO26s-seg model (104 fps, mAP50 = 0.712), which can be recommended for implementation in the production process. The obtained results confirm the effectiveness of the proposed method for automating quality control in the sorting of apple fruits

Keywords: COMPUTER VISION, IMAGE SEGMENTATION, YOLO26-SEG, APPLE FRUITS, APPLE LEAVES, FRUIT ROT, SORTING LINE, REAL-TIME, MACHINE LEARNING, TRANSFER LEARNING

<http://dx.doi.org/10.21515/1990-4665-218-021>

Внедрение систем технического зрения на базе методов машинного обучения и глубоких нейронных сетей является одним из приоритетных направлений автоматизации процессов послеуборочной обработки плодовой продукции [1]. Данные технологии позволяют существенно повысить объективность контроля качества и производительность сортировочных линий [2]. Однако в условиях реального производственного процесса объектом анализа видеосистемы является неоднородный по составу поток, содержащий, наряду с цельными плодами яблони, значительное количество растительных объектов (фрагменты листы) и механически поврежденных экземпляров (деформированные плоды). Присутствие данных объектов создает дополнительные сложности для системы распознавания, затрудняя сегментацию и классификацию продукции [3].

Поврежденные плоды яблони могут попадать на линию сортировки по ряду причин, связанных с технологическими этапами от сбора до обработки. На этапах уборки и транспортировки механизированный сбор, падение плодов при ручном сборе, а также вибрация и давление в

<http://ej.kubagro.ru/2026/04/pdf/21.pdf>

контейнерах приводят к появлению вмятин, трещин и полному разрушению плодов. При загрузке на линию перепад высот при опрокидывании контейнеров в приемный бункер, соударения на стыках конвейеров и механическое воздействие рабочих органов (щеток, роликов, калибровочных механизмов) могут вызывать повреждения плодов, уже имеющих микротрещины или скрытые дефекты. Гидрообработка (мойка) дополнительно ослабляет структуру поврежденных тканей, делая плоды более уязвимыми к последующим воздействиям [4-6].

Распознавание плодов с механическими повреждениями является важной технологической задачей по нескольким причинам. С санитарно-гигиенической точки зрения поврежденные плоды выделяют сок, который является идеальной питательной средой для развития микроорганизмов (плесени и бактерий) при контакте с лентой транспортера, роликами или щетками сок разносится по линии, что может привести к порче следующих за ними внешне здоровых плодов, вызывая перекрестное загрязнение всей партии [7]. Кроме того, сок от раздавленных плодов налипает на оптику камер, элементы осветителей и поверхности сортировочных узлов, что требует частых остановок линии для санитарной обработки.

Присутствие листьев яблони в сортируемом потоке существенно затрудняет распознавание целевых объектов. Они часто имеют округлую форму, зеленый или желто-красный цвет, что делает их визуально похожими на плоды яблони или дефекты плодов [8-10]. Введение отдельного класса «лист» позволяет корректно распознавать эти объекты, обеспечивая фильтрацию ложных срабатываний и повышая общую точность системы.

Цель исследования – разработка и экспериментальная валидация метода автоматического распознавания, сегментации и классификации некондиционных плодов яблони и листьев на сортировочной линии с

использованием нейросетевой модели YOLO26-seg для автоматизации контроля и повышения качества товарной продукции.

Материалы и методы. Для проведения исследований был сформирован датасет изображений, полученных в процессе движения плодов яблони на сортировочной линии. Фиксация видеоданных осуществлялась с помощью камеры DJI Action 5 Pro, установленной стационарно над конвейерной лентой. Съемка производилась с разрешением 1920×1080 пикселей при частоте 60 кадров в секунду. Из полученного видеопотока были выделены отдельные кадры, сформировавшие исходный массив данных для последующей обработки.

Разметка изображений выполнялась с использованием облачной платформы Roboflow, предназначенной для аннотирования данных в задачах компьютерного зрения. Процесс разметки был автоматизирован с применением модели Segment Anything 3 (SAM 3), что позволило существенно сократить временные затраты на подготовку датасета. Каждому обнаруженному объекту на изображении присваивалась соответствующая метка класса с построением масок сегментации (Segmentation masks). Всего было выделено три целевых класса: «apple» (целые плоды яблони), «leaf» (листья яблони) и «rotten» (деформированные плоды).

С целью повышения качества полученных масок была проведена экспертная валидация. Оператором вручную проверены и, при необходимости, откорректированы сегментационные маски для изображений датасета, отобранных случайным образом с соблюдением пропорций классов. Особое внимание уделялось сложным для автоматического выделения объектам: границам деформированных яблок (класс «rotten») с нечеткой текстурой и листьям («leaf») в условиях перекрытия.

Общий объем размеченных данных составил 1171 изображение (рисунок 1).

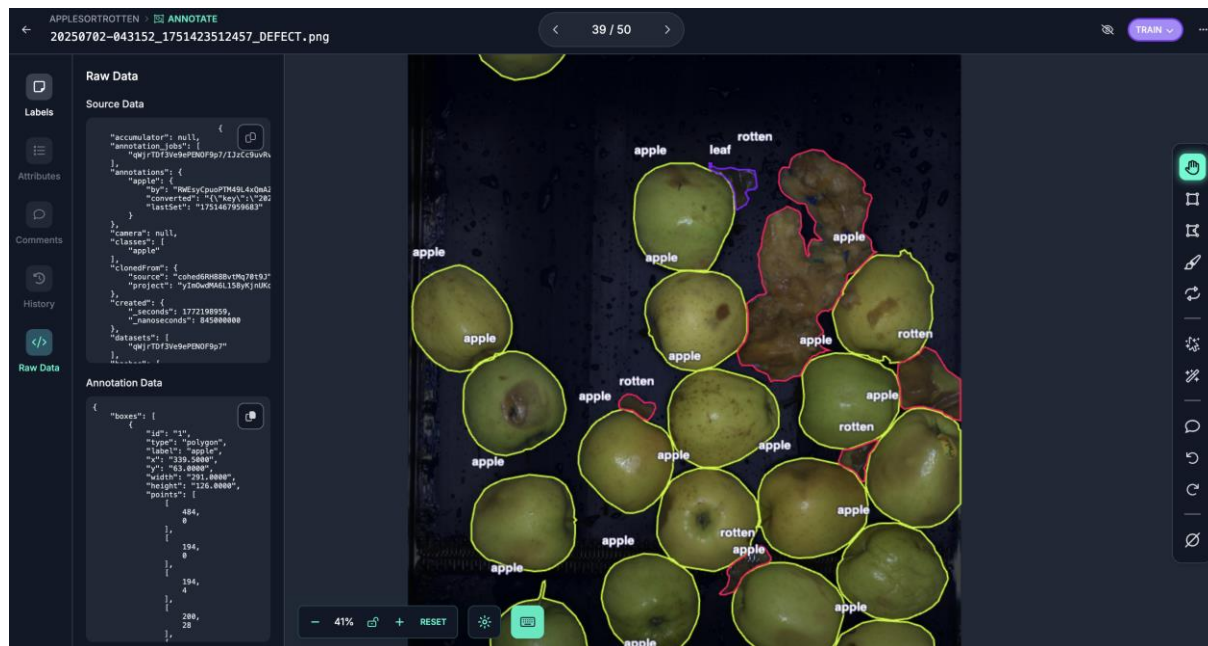


Рисунок 1 – процесс разметки изображений в облачной платформе

Roboflow

В качестве архитектуры нейронной сети выбрана модель YOLO26 (You Only Look Once), которая показывает высокую эффективность для задач распознавания объектов в реальном времени. Обучение проводилось методом трансферного обучения на основе предварительно обученной на наборе данных COCO модели, что позволило использовать ранее выделенные признаки и ускорить сходимость, сократить количество итераций (эпох обучения), необходимых модели для достижения оптимальных показателей на обучающей выборке. Размер входного изображения составлял 640×640 пикселей. Процесс обучения включал 300 эпох с применением механизма ранней остановки (early stopping) при отсутствии улучшения метрик на валидационной выборке в течение 40 эпох (параметр терпимости), что позволило предотвратить переобучение модели.

Для расширения набора данных и повышения обобщающей способности моделей при обучении была проведена аугментация размеченных изображений, размер которых был уменьшен до 640x640 пикселей в соответствии с требованиями архитектуры моделей YOLO (Resize). Выполнялось изменение яркости (Brightness) в диапазоне $\pm 10\%$ относительно исходного уровня. Дополнительно использовалось размытие движения (motion blur), имитирующее размытие изображения, возникающее при движении объектов на конвейерной ленте.

Для оценки качества обученных моделей использовались метрики, такие как точность (Precision) и полнота (Recall). Метрики позволяют оценить способность модели точно распознавать объекты каждого из трёх классов (формула 1,2):

$$\text{Precision}_{\text{Box/Mask}} = \frac{\text{TP}_{\text{Box/Mask}}}{\text{TP}_{\text{Box/Mask}} + \text{FP}_{\text{Box/Mask}}} \quad (1)$$

$$\text{Recall}_{\text{Box/Mask}} = \frac{\text{TP}_{\text{Box/Mask}}}{\text{TP}_{\text{Box/Mask}} + \text{FN}_{\text{Box/Mask}}} \quad (2)$$

где $\text{TP}_{\text{Box/Mask}}$ — количество верно обнаруженных ограничивающих рамок или пикселей масок объектов, $\text{FP}_{\text{Box/Mask}}$ — количество ложноположительных ограничивающих рамок или пикселей масок объектов, $\text{FN}_{\text{Box/Mask}}$ — количество ложноотрицательных ограничивающих рамок или пикселей масок объектов.

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

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

где N — количество классов объектов, $\text{AP}_{\text{Box/Mask},i}$ — площадь под кривой точности-полноты (Precision-Recall curve) для каждого класса i при использовании ограничивающих рамок или сегментационных масок.

Степень пересечения между предсказанными и истинными областями, метрика IoU (Intersection over Union) объектов определялась путем вычисления отношения площади пересечения ограничивающих рамок или масок к площади их объединения (формула 4).

$$\text{IoU} = \frac{A_{\text{intersection Box/Mask}}}{A_{\text{union Box/Mask}}} \quad (4)$$

где $A_{\text{intersection Box/Mask}}$ — площадь пересечения между двумя областями, а $A_{\text{union Box/Mask}}$ — площадь их объединения. Если перекрытие превышает установленный порог (например, 50%), объект считается успешно распознанным [10].

Обучение набора данных проводилось в среде Google Colab с использованием графического процессора NVIDIA Tesla T4. Полученная модель предназначалась для последующего анализа точности сегментации каждого из трех классов, а также для интеграции в систему автоматизированного подсчета объектов на сортировочной линии.

Результаты и обсуждение. В результате проведенных исследований эмпирическим путем определены наиболее эффективные параметры обучения моделей нейронных сетей YOLO26n-seg-YOLO26x-seg: размер изображений, подаваемых на вход модели для обучения и инференса — 640x640 пикселей, количество эпох обучения — 300, терпимость (Patience, т.е. количество эпох, в течение которых обучение модели продолжается, несмотря на отсутствие улучшения производительности на валидационном наборе данных) — 40, размер пакета данных (Batch Size, т.е. количество изображений, которые обрабатываются параллельно на каждой итерации обновления весов модели) — 6, место хранения данных (Cache) — облачная память.

Было проведено обучение пяти моделей семейства YOLO26-seg различной архитектурной ёмкости (n, s, m, l, x). Полученные результаты позволили провести анализ влияния количества параметров модели на

точность распознавания каждого типа объектов и определить оптимальную архитектуру для практического применения в составе системы технического зрения сортировочной линии (таблица 1).

Таблица 1 – Результаты вычисления метрик для оценки качества обученных моделей

Классы	Точность сегментации (Precision Mask)	Полнота сегментации (Recall Mask)	Средняя точность сегментации (mAP50 Mask)
YOLO26n-seg			
Плоды яблони «apple»	0,842	0,896	0,892
Листья яблони «leaf»	0,536	0,538	0,544
Деформированные плоды яблони «rotten»	0,568	0,586	0,587
Все классы all	0,637	0,683	0,618
YOLO26s-seg			
Плоды яблони «apple»	0,898	0,919	0,949
Листья яблони «leaf»	0,683	0,652	0,646
Деформированные плоды яблони «rotten»	0,618	0,657	0,623
Все классы all	0,751	0,693	0,712
YOLO26m-seg			
Плоды яблони «apple»	0,921	0,993	0,979
Листья яблони «leaf»	0,790	0,711	0,816
Деформированные плоды яблони «rotten»	0,621	0,695	0,686
Все классы all	0,795	0,775	0,829
YOLO26l-seg			
Плоды яблони «apple»	0,972	0,993	0,986
Листья яблони «leaf»	0,805	0,808	0,859
Деформированные плоды яблони «rotten»	0,764	0,759	0,775
Все классы all	0,794	0,819	0,841
YOLO26x-seg			
Плоды яблони «apple»	0,974	0,994	0,991
Листья яблони «leaf»	0,860	0,814	0,899
Деформированные плоды яблони «rotten»	0,860	0,826	0,831
Все классы all	0,865	0,887	0,890

В результате обучения моделей семейства YOLO26-seg для сегментации трёх классов («apple», «leaf», «rotten») были получены данные, позволяющие оценить влияние архитектурной сложности на точность распознавания каждого типа объектов. Наименьшие показатели зафиксированы у модели YOLO26n-seg (средняя точность mAP50 по всем классам 0,618), что объясняется ограниченной ёмкостью архитектуры, недостаточной для выделения сложных по форме объектов. По мере увеличения количества параметров моделей наблюдается устойчивый рост метрик: YOLO26s-seg достигает mAP50 = 0,712, YOLO26m-seg – 0,829, а максимальные значения показывают модели YOLO26l-seg (0,841) и YOLO26x-seg (0,890). Существенное улучшение метрик достигается при использовании архитектур с большим количеством параметров: YOLO26m-seg повышает mAP50 для листьев до 0,816, а лучший результат показывает YOLO26x-seg (Precision = 0,860, Recall = 0,814, mAP50 = 0,899). Это свидетельствует о высокой вариативности листы и необходимости более глубоких моделей для её выделения.

Следует отметить, что экспериментальная валидация разработанного метода проводилась на статичных изображениях, полученных в лабораторных условиях. Это не позволяет в полной мере оценить поведение модели при изменяющихся факторах реальной сортировочной линии, таких как колебания освещённости, варьирование скорости движения конвейерной ленты, появление новых сортов яблок, а также возможные загрязнения оптической системы. В ходе исследования для имитации некоторых условий реальной съёмки применялись методы аугментации (изменение яркости, размытие движения), однако они не могут полностью заменить натурные испытания. Сделанное заключение о пригодности модели для практического применения следует рассматривать как предварительное, основанное на достигнутых точностных показателях и производительности.

На рисунке 2 представлены примеры сегментации и классификации объектов на тестовых изображениях.




Рисунок 2 – Пример распознавания, сегментации и классификации плодов яблони и листьев с отображением контрольной зоны и автоматического подсчёта объектов

Дополнительно в правом нижнем углу выводится информация о доле площади кадра, занятой классом «rotten», что важно для санитарно-гигиенической оценки. Полученные визуальные результаты подтверждают, что модель YOLO26s-seg способна надёжно разделять

целевые классы даже в условиях частичного перекрытия объектов, а также обеспечивает необходимую точность для автоматического подсчёта продукции.

Возможность использования обученной модели в составе автоматизированной сортировочной линии определяется её способностью обрабатывать видеопоток в реальном времени. Для оценки производительности исследуемых архитектур были проанализированы временные затраты на каждом из последовательных этапов обработки кадра.

Время предобработки – интервал времени, затрачиваемый на подготовку исходного изображения перед обработкой нейронной сетью найден по формуле 5:

$$t_{pre} = t_{pre}^{end} - t_{pre}^{start} \quad (5)$$

где t_{pre}^{start} – момент начала операций предобработки, t_{pre}^{end} – момент их завершения.

Время инференса – интервал времени, необходимый для прямого прохода через нейросеть, в течение которого вычисляются выходные тензоры (ограничивающие рамки, маски сегментации, классы объектов) найдено по формуле 6:

$$t_{inf} = t_{ind}^{end} - t_{inf}^{start} \quad (6)$$

где t_{ind}^{end} – момент получения выходных тензоров, содержащих необработанные предсказания (логиты, координаты боксов, маски), t_{inf}^{start} – момент подачи предобработанного изображения на вход модели.

Время вычисления функции потерь – интервал времени, затраченный на расчёт значения функции потерь (loss), найдено по формуле 7:

$$t_{loss} = t_{loss}^{end} - t_{loss}^{start} \quad (7)$$

где t_{loss}^{end} и t_{loss}^{start} – моменты начала и окончания вычисления потерь соответственно.

Время постобработки – интервал времени, требуемый для преобразования выходных тензоров модели в итоговые предсказания (декодирование, фильтрация по порогу уверенности, подавление немаксимальных объектов, формирование масок сегментации и т.д.) (формула 8)

$$t_{post} = t_{post}^{end} - t_{post}^{start} \quad (8)$$

где t_{post}^{end} – момент получения финальных результатов детекции или сегментации, t_{post}^{start} – момент начала постобработки.

Общее время обработки одного изображения складывается из всех перечисленных составляющих (формула 9)

$$t_{total} = t_{pre} + t_{inf} + t_{loss} + t_{post} \quad (9)$$

Измерения временных характеристик проводились на вычислительной платформе Google Compute Engine с использованием графического процессора NVIDIA Tesla T4 (таблица 2). Конфигурация включала 12,7 ГБ оперативной памяти системы, 15,0 ГБ видеопамати и 112,6 ГБ дискового пространства.

Таблица 2 – Результаты вычисления временных характеристик

Модель	Предварительная обработка изображения, мс (preprocess)	Прямой проход через нейросеть, мс (inference)	Вычисление функции потерь, мс (loss)	Постобработка результатов, мс (postprocess)
YOLO26n-seg	0,4	1,8	0,0	5,4
YOLO26s-seg	0,6	2,5	0,0	6,5
YOLO26m-seg	1,1	3,6	0,0	4,6
YOLO26l-seg	0,6	3,8	0,0	6,9
YOLO26x-seg	0,6	4,6	0,0	7,8

Время предобработки для всех моделей не превышает 1,1 мс, (0,4 мс) отмечено у YOLO26n-seg, а максимальное (1,1 мс) – у YOLO26m-seg. Незначительные колебания этого параметра связаны с аппаратными особенностями.

Рост времени инференса наблюдается при увеличении архитектурной сложности: от 1,8 мс у YOLO26n-seg до 4,6 мс у YOLO26x-seg. Данная тенденция объясняется возрастанием числа параметров и объёма вычислений, выполняемых при прямом проходе через нейронную сеть.

Общее время обработки одного кадра, составляет для YOLO26n-seg 7,6 мс (131,6 кадра/с), для YOLO26s-seg – 9,6 мс (104,2 кадра/с), для YOLO26m-seg – 9,3 мс (107,5 кадра/с), для YOLO26l-seg – 11,3 мс (88,5 кадра/с), для YOLO26x-seg – 13,0 мс (76,9 кадра/с). Установлено, что модель YOLO26n-seg, обладая максимальной скоростью, уступает более крупным архитектурам по качеству распознавания, особенно для классов «leaf» и «rotten». YOLO26s-seg обеспечивает баланс: при частоте 104 кадра/с она показывает приемлемую точность для всех классов (mAP50 для «apple» – 0,949, для «leaf» – 0,646, для «rotten» – 0,623). Модели YOLO26m-seg и YOLO26l-seg показывают более высокое качество сегментации листьев и деформированных яблок при снижении скорости обработки видеопотока. Модель YOLO26x-seg, имея наилучшие показатели для класса «apple» (mAP50 = 0,991), характеризуется наибольшим временем обработки, однако её производительность (76,9 кадра/с) остаётся достаточной для практического применения в режиме реального времени.

Выводы. В результате проведенных исследований разработан метод автоматического распознавания, сегментации и классификации некондиционных плодов яблони и листьев на сортировочной линии с использованием нейросетевой модели YOLO26-seg для автоматизации

контроля и повышения качества товарной продукции. Проведён сравнительный анализ пяти архитектур семейства YOLO26-seg различной размерности (n, s, m, l, x), обученных на размеченном датасете из 1171 изображения с использованием методов аугментации. Установлено, что увеличение архитектурной сложности повышает точность сегментации. Анализ временных характеристик показал, что все исследуемые модели обеспечивают обработку видеопотока с частотой более 60 кадров в секунду. Оптимальный баланс между точностью и производительностью достигнут на модели YOLO26s-seg (частота 104 кадра/с, mAP50 = 0,712), которая может быть рекомендована для внедрения в производственный процесс.

Список использованной литературы

1. Gudkov, S. V., Matveeva, T. A., Sarimov, R. M., Simakin, A. V., Stepanova, E. V., Moskovskiy, M. N., Dorokhov, A. S., Izmailov, A. Y. Optical Methods for the Detection of Plant Pathogens and Diseases (Review) // *AgriEngineering*. – 2023. – №5. – P. 1789-1812.
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. – V. 16. – № 22. – P. 10084.
3. Kuttyrev, 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. 1006.
4. Azgomi, H., Haredasht, E.R., Motlagh, M.R.S. Diagnosis of some apple fruit diseases by using image processing and artificial neural network // *Food Control*. – 2023. – № 145. – 109484.
5. Fan, S., Li, J., Zhang, Y., Tian, X., Wang, Q., He, X., Zhang, C., Huang, W. On line detection of defective apples using computer vision system combined with deep learning methods // *J. Food Eng.* – 2020. – № 286. – 110102.
6. Wu, A., Zhu, J., Ren, T. Detection of apple defect using laser-induced light backscattering imaging and convolutional neural network // *Comput. Electr. Eng.* – 2020. – № 81. – 106454.
7. Toylan, H., Kuscu, H. A Real-Time Apple Grading System Using Multicolor Space // *Sci. World J.* – 2014. – 292681.
8. 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.
9. 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.

10. 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.

References

1. Gudkov, S. V., Matveeva, T. A., Sarimov, R. M., Simakin, A. V., Stepanova, E. V., Moskovskiy, M. N., Dorokhov, A. S., Izmailov, A. Y. Optical Methods for the Detection of Plant Pathogens and Diseases (Review) // AgriEngineering. – 2023. – №5. – P. 1789-1812.

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. – V. 16. – № 22. – P. 10084.

3. 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. 1006.

4. Azgomi, H., Haredasht, E.R., Motlagh, M.R.S. Diagnosis of some apple fruit diseases by using image processing and artificial neural network // Food Control. – 2023. – № 145. – 109484.

5. Fan, S., Li, J., Zhang, Y., Tian, X., Wang, Q., He, X., Zhang, C., Huang, W. On line detection of defective apples using computer vision system combined with deep learning methods // J. Food Eng. – 2020. – № 286. – 110102.

6. Wu, A., Zhu, J., Ren, T. Detection of apple defect using laser-induced light backscattering imaging and convolutional neural network // Comput. Electr. Eng. – 2020. – № 81. – 106454.

7. Toylan, H., Kuscü, H. A Real-Time Apple Grading System Using Multicolor Space // Sci. World J. – 2014. – 292681.

8. Kutyryov, A.I. Raspoznavanie i klassifikaciya boleznej list'ev yablони na osnove analiza ih izobrazhenij modelyami svertochnyh nejronnyh setej (CNN) // Vestnik Ul'yanovskoj gosudarstvennoj sel'skohozyajstvennoj akademii. – 2023. – № 3 (63). – S. 215-223.

9. Potapenkov, N.A., Kutyryov, A.I. Razrabotka modeli svyortochnoj nejronnoj seti dlya raspoznavaniya i klassifikacii plodov yablони na linii sortirovki // V sbornike: Innovacionnye tehnologii v agropromyshlennom komplekse v usloviyah cifrovoj transformacii. Materialy Mezhdunarodnoj nauchno-prakticheskoj konferencii. Volgograd, – 2025. – S. 225-231.

10. 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. – S. 56-63.