

## Применение алгоритмов компьютерного зрения и глубокого обучения для инвентаризации деревьев в садах интенсивного типа

✉ Кутырёв А.И.

Федеральный научный агроинженерный центр ВИМ

Москва, Россия

✉ e-mail: alexeykutyrev@gmail.com

Представлен метод мониторинга выпадов (погибшие деревья с признаками усыхания кроны и ствола) в интенсивных садах на основе аэрофотосъемки деревьев с беспилотного летательного аппарата DJI Mavic 3 Multispectral в междурядьях (высота съемки 1,5–2,0 м) и алгоритмов компьютерного зрения и глубокого обучения. Собран оригинальный датасет из 5366 изображений яблоневых садов, размеченный по трем классам: погибшие деревья (класс «Dead»), кандидаты на выпад (класс «Candidate») и молодые посадки (класс «Newly»). Аугментация данных (синтетическая генерация новых изображений на основе существующих) включала моделирование изменений освещенности ( $\pm 15\%$ ), цветового тона ( $-20^\circ$  по hue), гауссовского шума (0,5%) и размытия ( $\sigma = 0,5$  пикселя), что повысило устойчивость модели к работе в условиях садовых насаждений. Проведено сравнение пяти версий архитектуры YOLOv12; оптимальной признана модель YOLOv12l ( $mAP@50(B) = 0,810$ ; Precision = 0,820; Recall = 0,831), обеспечивающая баланс точности и производительности (9,58 мс/кадр). Разработано специализированное ПО с графическим интерфейсом, реализующее постобработку видеопотока, трекинг (отслеживание) объектов и визуализацию результатов. Использование алгоритма ByteTrack (с компенсацией движения камеры) позволило снизить число переключений ID распознанных классов деревьев до 2,3 на 1000 кадров и повысить точность распознавания до 92,4%, что на 41% превышает результаты распознавания без трекинга. Программа поддерживает настройку зоны анализа кадра в зависимости от параметров сада (ширина междурядий, угол съемки) и совместима с геоинформационными платформами, что позволяет формировать цифровые карты выпадов с привязкой к координатам GNSS-RTK. Практическая значимость полученных результатов заключается в уменьшении трудозатрат на инвентаризацию, повышении точности и скорости мониторинга состояния насаждений.

**Ключевые слова:** интенсивное садоводство, мониторинг, инвентаризация насаждений, компьютерное зрение, машинное обучение

## Application of computer vision and deep learning algorithms for tree inventory in intensive orchards

✉ Kutyrev A.I.

Federal Scientific Agroengineering Center VIM

Moscow, Russia

✉ e-mail: alexeykutyrev@gmail.com

A method for monitoring plant extinction (dead trees with signs of crown and trunk drying) in intensive orchards is presented based on aerial photography of trees from a DJI Mavic 3 Multispectral unmanned aerial vehicle in row spacing (shooting height 1.5–2.0 m) and computer vision and deep learning algorithms. An original dataset of 5,366 images of apple orchards was compiled, labeled into three classes: dead trees (class "Dead"), candidates for plant extinction (class "Candidate"), and

young plantings (class "Newly"). Data augmentation (synthetic generation of new images based on the existing ones) included modeling of the changes in illumination ( $\pm 15\%$ ), color tone ( $-20^\circ$  in hue), Gaussian noise (0.5%), and blur ( $\sigma = 0.5$  pixels), which increased the model's robustness to work in garden planting conditions. Five versions of the YOLOv12 architecture were compared; the YOLOv12l model was recognized as optimal (mAP@50(B) = 0.810; Precision = 0.820; Recall = 0.831), providing a balance between accuracy and performance (9.58 ms/frame). Specialized software with a graphical interface was developed that implements video stream post-processing, object tracking, and visualization of results. The use of the ByteTrack algorithm (with camera motion compensation) allowed reducing the number of ID switches of the recognized tree classes to 2.3 per 1000 frames and increasing the recognition accuracy to 92.4%, which is 41.0% higher than the recognition results without tracking. The program supports customization of the frame analysis zone depending on garden parameters (row spacing, shooting angle) and is compatible with geoinformation platforms, allowing the creation of digital maps of crop losses referenced to GNSS-RTK coordinates. The practical significance of the obtained results lies in the reduction of labor costs for inventory, and the increase in the accuracy and speed of monitoring the condition of the plantings.

**Keywords:** intensive horticulture, monitoring, plantation inventory, computer vision, machine learning

**Для цитирования:** Кутырёв А.И. Применение алгоритмов компьютерного зрения и глубокого обучения для инвентаризации деревьев в садах интенсивного типа // Сибирский вестник сельскохозяйственной науки. 2026. Т. 56. № 2. С. 90–100. <https://doi.org/10.26898/0370-8799-2026-2-10>

**For citation:** Kutyrev A.I. Application of computer vision and deep learning algorithms for tree inventory in intensive orchards. *Sibirskii vestnik sel'skokhozyaistvennoi nauki = Siberian Herald of Agricultural Science*, 2026, vol. 56, no. 2, pp. 90–100. <https://doi.org/10.26898/0370-8799-2026-2-10>

#### Конфликт интересов

Автор заявляет об отсутствии конфликта интересов.

#### Conflict of interest

The author declare no conflict of intrerst.

#### Благодарность

Работа выполнена при поддержке Минобрнауки России в рамках государственного задания ФГБНУ «Федеральный научный агроинженерный центр ВИМ» (тема № FGUN-2022-0011).

#### Acknowledgements

The research was carried out under the support of the Ministry of Science and Higher Education of the Russian Federation within the state assignment of the Federal Scientific Agroengineering Center VIM (theme No. FGUN-2022-0011).

## ВВЕДЕНИЕ

Один из основных факторов продуктивности и эффективности интенсивных садов с плотностью посадки до 2–3 тыс. деревьев/га – сохранение полноты рядов. Выпады (погибшие деревья с признаками усыхания крон и стволов) нарушают равномерность распределения растений, структуру рядов, снижают эффективность механизированных операций, увеличивают эксплуатационные затраты и ведут к потере урожая до 15–20% [1, 2]. При этом традиционные методы инвентаризации насаждений, основанные на их осмотре агрономами, обладают высокой субъективностью, требуют значительных трудозатрат и не масштабируются на большие площади [3].

Современные технологии съемки с помощью беспилотных летательных аппаратов (БПЛА) в сочетании с методами компьютерного зрения позволяют автоматизировать мониторинг и сократить время на обследования насаждений. В большинстве исследований для мониторинга насаждений применяют RGB-камеры, которые, в отличие от LiDAR или мультиспектральных систем, обеспечивают достаточную информативность при значительно меньшей сложности обработки данных [4]. В исследовании [5] предложена система с использованием изображений, полученных с помощью БПЛА, и методы распознавания и анализа состояния деревьев. Аналогичные подходы описаны в работах [6, 7], где применение БПЛА с RGB-камерами и алгоритмов глубокого обучения позволило

проводить подсчет и классификацию деревьев, а также с высокой точностью выявлять пропуски в рядах.

Несмотря на существующие разработки, остаются нерешенными ключевые научные задачи, определяющие актуальность данного исследования:

- отсутствие специализированных методов для точного учета выпадов деревьев с использованием БПЛА. Большинство из них используют данные дистанционного зондирования (высота съемки 20–100 м) [5, 6], где разрешающая способность недостаточна для распознавания визуальных признаков усыхания деревьев. Также данные методы ориентированы на подсчет пропусков в рядах садовых насаждений. Предлагаемый метод основан на съемке деревьев в междурядьях (высота съемки 1,5–2,0 м), что дает возможность диагностировать отдельные растения;

- отсутствие эффективных методов трекинга (отслеживания) деревьев на видеоданных, получаемых с БПЛА. Проведение съемки в междурядьях с малой высоты для распознавания деревьев предполагает использование видеопотока. При этом существующие методы обработки изображений с БПЛА ориентированы на одиночные (статичные) снимки, ортофотопланы высокого разрешения [8] и не решают проблему, возникающую при анализе последовательных кадров: одно и то же дерево на разных кадрах распознается как разные объекты, что приводит к значительным ошибкам при итоговой количественной оценке выпадов;

- недостаточная адаптивность к изменяющимся условиям съемки садовых насаждений. Существующие алгоритмы компьютерного зрения показывают снижение точности при вариациях естественного освещения и взаимных перекрытиях крон деревьев в плотных посадках. Это ограничивает их практическое применение в производственных условиях, где визуальные характеристики плодовых деревьев могут значительно варьироваться [9]. В предлагаемом методе данная проблема решена через комплекс мер по повышению робастности, включая аугментацию данных и использование современной архитектуры нейронной сети, оптимизированной для работы с изменчивыми визуальными признаками.

Цель исследования – разработать метод мониторинга выпадов плодовых деревьев в рядах интенсивных садов.

Предлагаемый метод интегрирует высокоточное распознавание деревьев на основе современной модели сверточной нейронной сети YOLOv12, устойчивый трекинг для минимизации ошибок распознавания и специализированное программное обеспечение (ПО), адаптированное для задач инвентаризации садовых насаждений.

## МАТЕРИАЛ И МЕТОДЫ

Современные модели сверточных нейронных сетей, обученные на разнородных наборах данных, показывают высокую точность и производительность при распознавании биологических объектов [10, 11]. Среди наиболее распространенных архитектур можно выделить Faster R-CNN, RetinaNet, EfficientDet и семейство моделей YOLO (You Only Look Once). Анализ показывает, что YOLOv12 устраняет ключевые недостатки известных архитектур за счет использования модуля Area Attention и оптимизированной сети агрегации признаков R-ELAN (Residual Efficient Layer Aggregation Network) модель корректирует освещение, повышая точность распознавания объектов. Использование сверток ( $7 \times 7$ ) и многомасштабных признаков позволяет значительно повысить точность распознавания объектов разных размеров и форм [12, 13]. Для проведения экспериментов выбраны различные конфигурации модели YOLOv12, от нано (n) до экстра (x), отличающиеся вычислительной сложностью и количеством обучаемых параметров. В целях оптимизации процесса обучения использован метод трансферного обучения [12]. Начальная инициализация весовых коэффициентов осуществлена на основе моделей YOLOv12, прошедших обучение на датасете COCO (более 330 тыс. размеченных изображений, 80 категорий).

При аэрофотосъемке рядов садовых насаждений применяли RGB-камеру беспилотного летательного аппарата DJI Mavic 3 Multispectral с пролетами вдоль междурядий на высоте 1,5–2,0 м при разнообразных условиях естественной освещенности (см. рис. 1).



**Рис. 1.** Проведение аэрофотосъемки в междурядьях сада с использованием БПЛА DJI Mavic 3 Multispectral

**Fig. 1.** Conducting aerial photography in the orchard rows using the DJI Mavic 3 Multispectral UAV

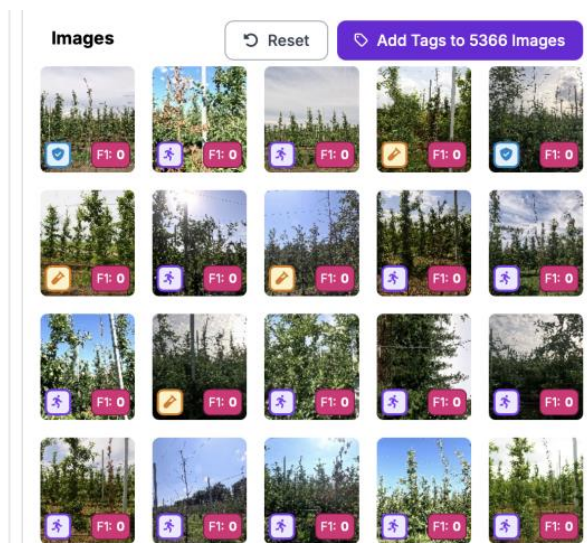
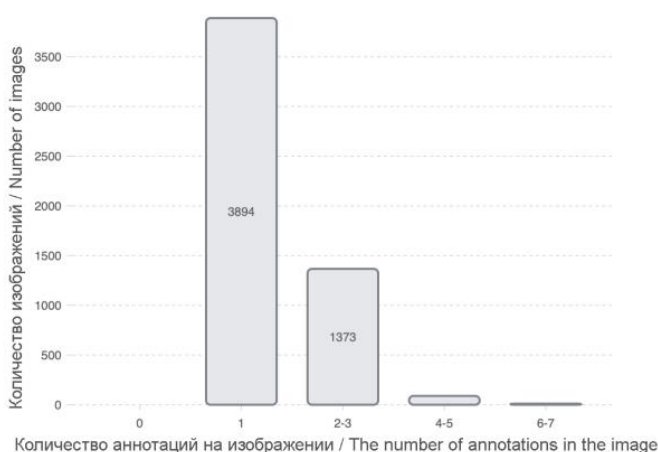
Для обучения модели использован собранный репрезентативный датасет, включающий 5366 размеченных изображений, сформированный в условиях промышленных яблоневых садов интенсивного типа (ООО «Зоринский сад», Курская область, Обоянский район, с. Зорино) (см. рис. 2).

Исходные изображения для разметки имели разрешение  $4032 \times 3024$  пикселя, что обеспечивало высокий уровень детализации для точного распознавания характерных признаков усыхания кроны и стволов.

Разметка изображений (выделение деревьев ограничивающими рамками) выполнена с помощью платформы RoboFlow. На изображениях размечены три класса объектов:

- «Dead», погибшие деревья с признаками усыхания кроны и ствола (5547 аннотаций);
- «Candidate», деревья с пограничными признаками жизненного состояния, требующие дополнительного мониторинга (1720 аннотаций);
- «Newly», вновь высаженные молодые деревья, отличающиеся морфологическими особенностями и размерами (711 аннотаций).

Разметка нескольких классов позволила перейти от бинарной классификации «дерево/фон» к многофакторному анализу состояния насаждений.



**Рис. 2.** Распределение изображений по количеству аннотаций и примеры кадров из датасета, сформированного в условиях промышленных яблоневых садов интенсивного типа

**Fig. 2.** Distribution of the images according to annotation count and frame examples from a dataset captured in industrial-scale intensive type apple orchards

Для повышения адаптивности модели к различным условиям эксплуатации и расширения обучающей выборки проведена аугментация данных (синтетическая генерация новых изображений на основе существующих) (см. рис. 3).

Она включала изменение яркости ( $\pm 15\%$ ), цветового тона (hue  $-20^\circ$ ), добавление гауссовского шума (0,5%) и размытия ( $\sigma = 0,5$  пикселя). Эти преобразования имитировали различные условия освещенности, сезонные изменения и аппаратные погрешности, что позволило увеличить исходный датасет от 5366 до 11 865 изображений и улучшить обобщающую способность модели. Полученный набор данных разделен на обучающую (70%), валидационную (15%) и тестовую (15%) выборки с сохранением баланса классов.

Для оценки качества работы моделей использованы общепринятые метрики средней точности в распознавании ограничивающих рамок (mAP@50(B)), а также метрики полноты (Recall) и точности (Precision). Дополнительно рассчитаны F1-мера (среднее гармоническое значение между Precision и Recall), IoU (Intersection over Union) для оценки перекрытия предсказанных и истинных рамок, а также FPS (Frames Per Second) – скорость

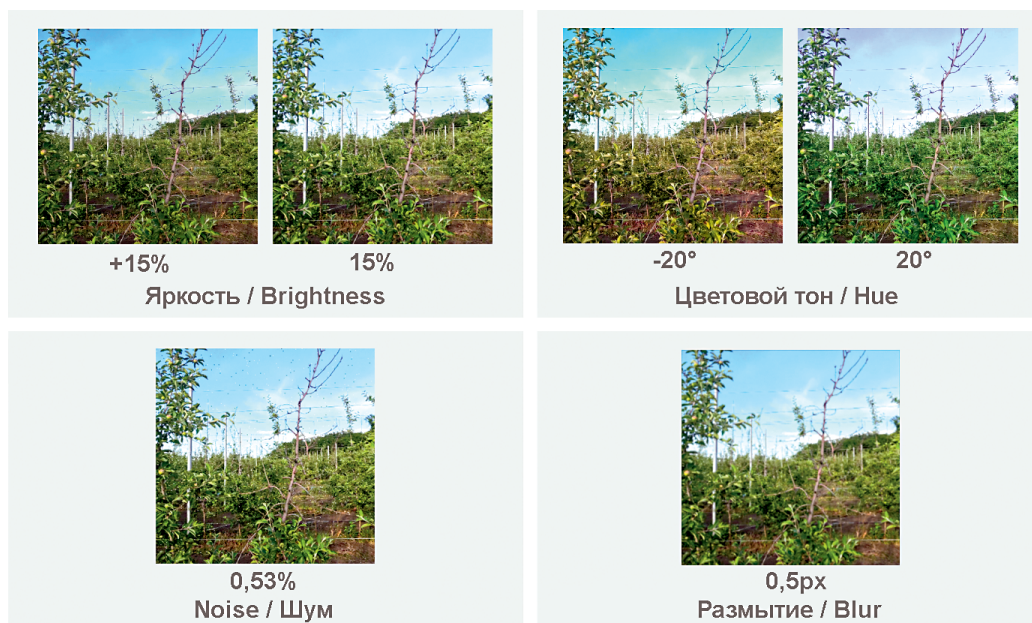
обработки кадров. Для анализа сходимости обучения фиксировали значения Loss-функции (функции потерь, ошибки предсказания наличия объекта и классификации) по эпохам обучения [14].

Эксперименты проводили на вычислительном комплексе с двумя видеокартами NVIDIA GeForce RTX 2080 Ti. Для реализации алгоритмов глубокого обучения использовали фреймворк PyTorch и библиотеку Ultralytics, а для обработки данных и визуализации – библиотеки OpenCV, NumPy и Matplotlib.

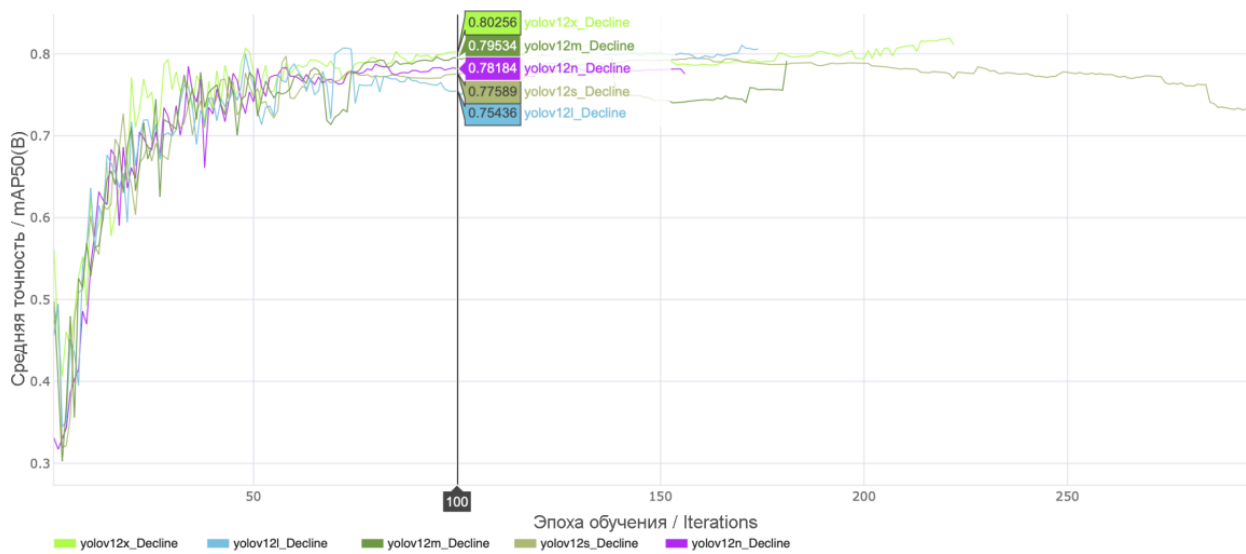
## РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

В результате проведенных экспериментов обучены модели YOLOv12 в пяти версиях: YOLOv12n (nano), YOLOv12s (small), YOLOv12m (medium), YOLOv12l (large) и YOLOv12x (extra large). Динамика изменения метрики средней точности mAP@50(B) в процессе обучения моделей представлена на рис. 4.

Проведено сравнение пяти версий YOLOv12 (n, s, m, l, x). Наивысшую точность (mAP@50 = 0,811) показала YOLOv12x, однако ее ресурсоемкость (199,0 GFLOPs) ограничивает практическое применение. Модели YOLOv12n и YOLOv12s обеспечили высо-



**Рис. 3.** Используемые методы аугментации набора данных  
**Fig. 3.** Methods used for dataset augmentation



**Рис. 4.** График зависимости средней точности моделей (метрика mAP@50(B)) от эпохи обучения

**Fig. 4.** Graph of the dependence of the average precision of models (mAP@50(B) metric) on the training epoch

кую скорость инференса (3,34–3,85 мс/кадр), но с более низкой точностью. При этом наименьшее значение ошибки (Box Loss = 1,51) показала модель YOLOv12n, что объясняется ее менее сложной архитектурой. Модель YOLOv12l показала оптимальный баланс между точностью (mAP@50 = 0,810, Precision = 0,820, Recall = 0,831) и производительностью (9,58 мс/кадр). Анализ функции потерь показал, что минимальные значения ошибок достигаются к 45-й эпохе, после чего начинается переобучение. Дополнительно рассчитанные метрики (mAP@50-95, F1-score, IoU и FPS) подтвердили выявленные закономерности, поэтому модель YOLOv12l выбрана как наиболее рациональная для постобработки видеоматериалов.

В результате проведенных исследований разработано ПО на языке Python с графическим интерфейсом, реализующее полный цикл постобработки видеоданных с помощью модели YOLOv12l: от загрузки исходных видеофайлов, полученных с помощью RGB-камеры квадрокоптера DJI Mavic 3 Multispectral, до анализа, визуализации и экспорта результатов (см. рис. 5).

Разработанное ПО поддерживает полный цикл обработки видеоданных, включая распознавание объектов с трекингом, филь-

трацию результатов по порогу уверенности, подавление дублирующих детекций (Non-Maximum Suppression) и настройку зоны анализа кадра (ширина междурядий, угол съемки и др.). Реализованы автоматический выбор вычислительных ресурсов (CPU/GPU), сохранение результатов в базу данных (SQLite) и экспорт в различные форматы (.txt и .xlsx) с логированием всех параметров.

Устойчивое сопровождение объектов между кадрами обеспечивается алгоритмами трекинга (ByteTrack, BoT-SORT, OC-SORT), использующими кинематические и визуальные признаки объектов (см. рис. 6).

В интерфейсе программы реализована настройка параметров трекинга: порог уверенности для инициализации нового ID (new\_track\_thresh), время сохранения ID при временном пропадании объекта из кадра (track\_buffer), пороги сопоставления по перекрытию и близости объектов (match\_thresh, proximity\_thresh), а также метод компенсации движения камеры (gmc\_method) для стабилизации трекинга. Настройка этих параметров минимизирует частоту переключения идентификаторов и обеспечивает стабильное сопровождение деревьев на видеокадрах вдоль ряда. По результатам обработки видео программа автоматически сохраняет изобра-

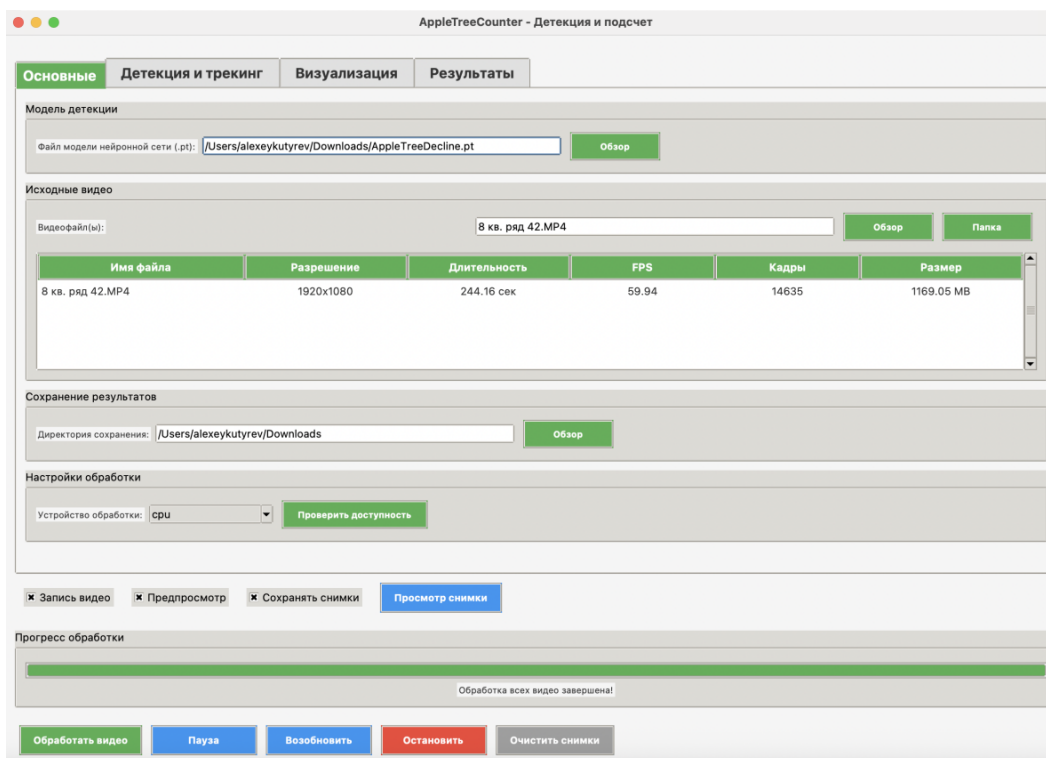


Рис. 5. Интерфейс программы для постобработки видеоданных и мониторинга выпадов в рядах интенсивных садов

Fig. 5. Interface of the program for video data post-processing and monitoring of plant extinction in the rows of intensive orchards

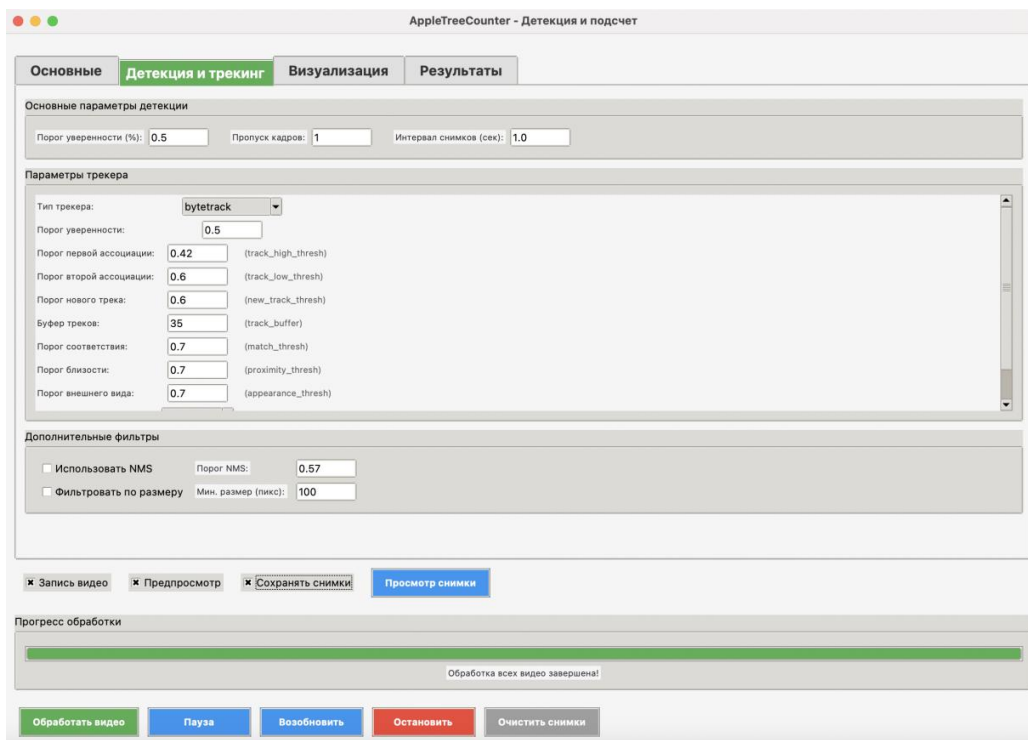


Рис. 6. Вкладка «Детекция и трекинг» в интерфейсе программы, настройка алгоритмов трекинга

Fig. 6. "Detection and Tracking" tab in the program interface, configuration of the tracking algorithms

жения с распознанными выпадами и формирует отчет.

Экспериментальная оценка алгоритмов трекинга объектов проведена на видеозаписях в разрешении 1920 × 1080 пикселей с частотой 60 кадров/с, полученных с БПЛА в междурядьях при различной освещенности. Для каждого алгоритма трекинга подбирали параметры, после этого фиксировали метрики стабильности сопровождения объектов на кадрах: число переключений ID на 1000 кадров, доля корректно сохраненных ID на протяжении ряда, а также доля верно распознанных выпадов (метрики точности и полноты по кадрам) и средняя скорость обработки (кадров/с).

На рис. 7 представлен пример работы программы: в ряду из 224 деревьев (длина ряда 216 м) распознано 27 выпадов, классы «Dead» и «Candidate».

В ходе экспериментальной оценки алгоритмов трекинга установлено, что алгоритм ByteTrack показывает наилучшие результаты по ключевым для задачи инвентаризации параметрам, обеспечивает минимальное количество переключений идентификаторов (в среднем 2,3 на 1000 кадров) и наивысшую устойчивость сопровождения (95,7% сохраненных ID) (см. таблицу).

Установлено, что основные ошибки классификации (~15% случаев) связаны со схожестью визуальных признаков классов погибших деревьев (класс «Dead») и деревьев с пограничными признаками жизненного состояния (класс «Candidate»).

Для комплексной оценки эффективности проведен расчет интегральной метрики, объединяющей точность распознавания и ста-



**Рис. 7.** Пример работы программы: результаты распознавания выпадов в рядах садовых насаждений  
**Fig. 7.** Example of program operation: results of recognition of plant extinction in the rows of orchard plantings

Результаты проведения экспериментальной оценки различных алгоритмов трекинга  
 Results of conducting an experimental evaluation of various tracking algorithms

Алгоритм	Среднее число переключений ID на 1000 кадров	Сохраненные ID (устойчивость сопровождения объектов на видео кадрах), %	Точность распознавания выпадов по метрике Precision, %	Полнота распознавания выпадов по метрике Recall, %	Скорость обработки кадров, FPS, кадров/с
ByteTrack	2,3	95,7	92,4	89,1	102
BoT-SORT	3,1	93,2	90,8	87,5	96
OC-SORT	5,8	88,4	85,6	84,9	110

бильность отслеживания деревьев в кадре с использованием формулы

$$A_{track} = \left( \frac{TP}{TP + FR} \right) \left( 1 - \frac{N_{sw}}{N_{obj}} \right),$$

где  $A_{track}$  – интегральная точность распознавания с учетом трекинга,  $TP$  – число истинно положительных детекций (верно распознанных деревьев);  $FR$  – число ложно положительных детекций (ошибочно распознанных деревьев);  $N_{sw}$  – количество переключений ID за анализируемый видеосегмент,  $N_{obj}$  – общее число уникальных объектов (деревьев), участвующих в трекинге.

Использование этой метрики дало возможность более достоверно оценить влияние трекинга на конечную точность инвентаризации. Применение алгоритма ByteTrack с компенсацией движения камеры (GMC) позволило достичь точности распознавания выпадов 92,4%. Данный результат на 41% превышает точность распознавания без применения алгоритмов трекинга. Это подтверждает его существенную роль в повышении надежности разработанного метода.

Разработанный метод на основе YOLOv12l и ByteTrack показал высокую эффективность для мониторинга выпадов в интенсивных садах. Важным преимуществом стала интеграция с геоинформационными системами [15]: использование БЛА Mavic 3 Multispectral с GNSS-приемником позволяет осуществлять точную геопривязку распознанных выпадов и формировать цифровые карты для импорта в QGIS или ArcGIS.

## ВЫВОДЫ

1. В результате исследования разработан метод мониторинга выпадов деревьев в интенсивных садах на основе RGB-аэрофото съемки с малой высоты (1,5–2,0 м) и алгоритмов глубокого обучения. Проведенное сравнение пяти версий архитектуры YOLOv12 показало, что модель YOLOv12l обеспечивает оптимальное соотношение вычислительной эффективности и точности распознавания ( $mAP@50(B) = 0,81$ ;  $Precision = 0,82$ ;  $Recall = 0,83$ ) и может быть рекомендована для постобработки видеоданных, полученных

с БЛА в междурядьях, что позволяет диагностировать состояние отдельных растений.

2. Разработанное ПО с графическим интерфейсом обеспечивает полный цикл анализа данных – от загрузки видео до визуализации и экспорта результатов. Использование модели YOLOv12l в сочетании с алгоритмом трекинга ByteTrack обеспечило стабильное сопровождение деревьев между кадрами, что позволило повысить точность распознавания выпадов до 92,4% и минимизировать количество ошибок, связанных с переключением идентификаторов.

3. Использование аугментации данных на этапе обучения модели позволило создать систему, обладающую высокой адаптивностью к различным условиям освещенности и плотности посадки, что подтверждает ее применимость для мониторинга насаждений в производственных условиях.

## СПИСОК ЛИТЕРАТУРЫ

1. Laužikė K., Uselis N., Kviklys D., Samuolienė G. Orchard Planting Density and Tree Development Stage Affects Physiological Processes of Apple (*Malus domestica* Borkh.) Tree // *Agronomy*. 2020. Vol. 10 (12). P. 1912. DOI: 10.3390/agronomy10121912.
2. Starkus A., Morkūnaitė-Haimi Š., Gurskas T., Misiukevičius E., Stanys V., Frercks B. The Biological and Genetic Mechanisms of Fruit Drop in Apple Tree (*Malus × domestica* Borkh.) // *Horticulturae*. 2024. Vol. 10 (9). P. 987. DOI: 10.3390/horticulturae10090987.
3. Sekharamanry P.K., Melgani F., Malacarne J., Ricci R., de Almeida Silva R., Marcato Junior J. A Seamless Deep Learning Approach for Apple Detection, Depth Estimation, and Tracking Using YOLO Models Enhanced by Multi-Head Attention Mechanism // *Computers*. 2024. Vol. 13 (3). P. 83. DOI: 10.3390/computers13030083.
4. Panigrahi S.S., Singh K.D., Balasubramanian P., Wang H., Natarajan M., Ravichandran P. UAV-Based LiDAR and Multispectral Imaging for Estimating Dry Bean Plant Height, Lodging and Seed Yield // *Sensors*. 2025. Vol. 25 (11). P. 3535. DOI: 10.3390/s25113535.
5. Jemaa H., Bouachir W., Leblon B., LaRocque A., Haddadi A., Bouguila N. UAV-Based Computer

- Vision System for Orchard Apple Tree Detection and Health Assessment // *Remote Sens.* 2023. Vol. 15 (14). P. 3558. DOI: 10.3390/rs15143558.
6. Hobart M., Pflanz M., Tsoulas N., Weltzien C., Kopetzky M., Schirrmann M. Fruit Detection and Yield Mass Estimation from a UAV Based RGB Dense Cloud for an Apple Orchard // *Drones.* 2025. Vol. 9 (1). P. 60. DOI: 10.3390/drones9010060.
  7. Yang R., Yuan D., Zhao M., Zhao Z., Zhang L., Fan Y., Liang G., Zhou Y. Camellia oleifera Tree Detection and Counting Based on UAV RGB Image and YOLOv8 // *Agriculture.* 2024. Vol. 14 (10). P. 1789. DOI: 10.3390/agriculture14101789.
  8. Han P., Ma C., Chen J., Chen L., Bu S., Xu S., Zhao Y., Zhang C., Hagino T. Fast Tree Detection and Counting on UAVs for Sequential Aerial Images with Generating Orthophoto Mosaicing // *Remote Sens.* 2022. Vol. 14. P. 4113. DOI: 10.3390/rs14164113.
  9. Kutyrev A., Andriyanov N., Khort D., Smirnov I., Zubina V. Adaptive CNN Ensemble for Apple Detection: Enabling Sustainable Monitoring Orchard // *AgriEngineering.* 2025. Vol. 7 (11). P. 369. DOI: 10.3390/agriengineering7110369.
  10. Ali M.L., Zhang Z. The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection // *Computers* 2024. Vol. 13 (12). P. 336. DOI: 10.3390/computers13120336.
  11. Lv M., Xu Y.-X., Miao Y.-H., Su W.-H. A Comprehensive Review of Deep Learning in Computer Vision for Monitoring Apple Tree Growth and Fruit Production // *Sensors.* 2025. Vol. 25 (8). P. 2433. DOI: 10.3390/s25082433.
  12. Yang Z., Khan Z., Shen Y., Liu H. GT-DR-YOLOv12: Optimizing YOLO for Efficient and Accurate Weed Detection in Agriculture // *Agronomy.* 2025. Vol. 15 (8). P. 1824. DOI: 10.3390/agronomy15081824.
  13. Ribeiro D., Tavares D., Tiradentes E., Santos F., Rodriguez D. Performance Evaluation of YOLOv11 and YOLOv12 Deep Learning Architectures for Automated Detection and Classification of Immature Macauba (*Acrocomia aculeata*) Fruits // *Agriculture.* 2025. Vol. 15 (15). P. 1571. DOI: 10.3390/agriculture15151571.
  14. Padilla R., Passos W.L., Dias T.L.B., Netto S.L., da Silva E.A.B. A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit // *Electronics.* 2021. Vol. 10 (3). P. 279. DOI: 10.3390/electronics10030279.
  15. Хорт Д.О., Кутырев А.И., Смирнов И.Г., Воронков И.В. Разработка системы автоматизированного управления агротехнологиями в садоводстве // *Сельскохозяйственные машины и технологии.* 2021. Т. 15. № 2. С. 61–68. DOI: 10.22314/2073-7599-2021-15-2-61-68.

## REFERENCES

8. Han P., Ma C., Chen J., Chen L., Bu S., Xu S., Zhao Y., Zhang C., Hagino T. Fast Tree Detection and Counting on UAVs for Sequential Aerial Images with Generating Orthophoto Mosaicing. *Remote Sens*, 2022, vol. 14, p. 4113. DOI: 10.3390/rs14164113.
9. Kutyrev A., Andriyanov N., Khort D., Smirnov I., Zubina V. Adaptive CNN Ensemble for Apple Detection: Enabling Sustainable Monitoring Orchard. *AgriEngineering*, 2025, vol. 7(11), p. 369. DOI: 10.3390/agriengineering7110369.
10. Ali M.L., Zhang Z. The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection. *Computers*, 2024, vol. 13 (12), p. 336. DOI: 10.3390/computers13120336.
11. Lv M., Xu Y.-X., Miao Y.-H., Su W.-H. A Comprehensive Review of Deep Learning in Computer Vision for Monitoring Apple Tree Growth and Fruit Production. *Sensors*, 2025, vol. 25 (8), p. 2433. DOI: 10.3390/s25082433.
12. Yang Z., Khan Z., Shen Y., Liu H. GTDR-YOLOv12: Optimizing YOLO for Efficient and Accurate Weed Detection in Agriculture. *Agronomy*, 2025, vol. 15 (8), p. 1824. DOI: 10.3390/agronomy15081824.
13. Ribeiro D., Tavares D., Tiradentes E., Santos F., Rodriguez D. Performance Evaluation of YOLOv11 and YOLOv12 Deep Learning Architectures for Automated Detection and Classification of Immature Macauba (*Acrocomia aculeata*) Fruits. *Agriculture*, 2025, vol. 15 (15), p. 1571. DOI: 10.3390/agriculture15151571.
14. Padilla R., Passos W.L., Dias T.L.B., Netto S.L., da Silva E.A.B. A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. *Electronics*, 2021, vol. 10 (3), p. 279. DOI: 10.3390/electronics10030279.
15. Hort D.O., Kutyrev A.I., Smirnov I.G., Voronkov I.V. Development of an automated management system for agricultural technologies in horticulture. *Sel'skohozyajstvennyye mashiny i tekhnologii=Agricultural machinery and technology*. 2021, vol. 15 (2), pp. 61–68. (In Russian). DOI: 10.22314/2073-7599-2021-15-2-61-68.

#### СВЕДЕНИЯ ОБ АВТОРЕ

✉ **Кутырёв Алексей Игоревич**, заведующий лабораторией, ведущий научный сотрудник; **адрес для переписки:** Россия, 109428, Москва 1-й Институтский проезд, 5; SPIN-код 9793-5074, ORCID 0000-0001-7643-775X; e-mail: alexeykutyrev@gmail.com

#### AUTHOR INFORMATION

✉ **Alexey I. Kutyrev**, Laboratory Head, Lead Researcher; **address:** 5, 1st Institute passage, Moscow, 109428, Russia; SPIN-code 9793-5074, ORCID 0000-0001-7643-775X; e-mail: alexeykutyrev@gmail.com

Дата поступления статьи / Received by the editors 19.11.2025  
Дата принятия к публикации / Accepted for publication 08.12.2025  
Дата публикации / Published 10.03.2026