

МЕХАНИЗАЦИЯ, ЭЛЕКТРИФИКАЦИЯ, АВТОМАТИЗАЦИЯ / MECHANIZATION, ELECTRIFICATION, AUTOMATION

<https://doi.org/10.30766/2072-9081.2026.27.2.480-492>

УДК 631.171:004.3:004.932



Применение компьютерного зрения и глубокого обучения для автоматизированного мониторинга роста растений земляники садовой

© 2026. А. И. Кутырёв ✉, Р. А. Филиппов

ФГБНУ «Федеральный научный агроинженерный центр ВИМ», г. Москва,
Российская Федерация

В статье представлен разработанный алгоритм и программное обеспечение для автоматизированного мониторинга роста растений земляники садовой с применением нейросетевых технологий. Модели YOLO11x и YOLOx-seg, предварительно обученные методом трансферного обучения (transfer learning), адаптированы для распознавания и классификации растений (класс «plant»), листьев (класс «leaf») и эталонного маркера (класс «ref_obj») известного размера. Сегментация листьев земляники с помощью модели YOLO11x-seg позволяет анализировать морфометрические параметры отдельных листовых пластин (площадь, периметр, округлость, соотношение сторон). Сформирован и аннотирован набор RGB-изображений (2000 шт.), полученных с использованием камеры GoPro HERO11, в контролируемых лабораторных условиях, с последующей аугментацией для повышения устойчивости модели к вариациям условий съемки. Разработанный алгоритм преобразует координаты ограничивающих рамок (bounding boxes) и масок сегментации распознанных объектов в метрические единицы через калибровочные коэффициенты, вычисляемые по маркеру известного размера (100×100 мм). Программное обеспечение, реализованное с применением библиотек PyQt5, TensorFlow, Keras, OpenCV, предоставляет не только визуализацию результатов, но и хранение данных в локальной базе SQLite с возможностью экспорта в форматы JSON и Excel. Валидация модели показала высокую точность детектирования ограничивающих рамок растений (mAP50 = 0,906) и сегментации листьев (mAP50-mask = 0,625). Средняя скорость обработки составила 20,3 мс/кадр для детектирования и 34,5 мс/кадр для сегментации. Погрешность измерений составила менее 3,5 % для габаритных параметров растения и 5,2 % для морфометрических показателей листьев, подтверждая эффективность метода для оценки высоты, ширины и площади растений, а также анализа листового аппарата. Результаты исследований показали перспективность подхода для автоматизации фенотипирования растений в режиме реального времени.

Ключевые слова: машинное обучение, обработка изображений, неинвазивный мониторинг, сегментация, нейросетевые технологии

Благодарности: работа выполнена при поддержке Минобрнауки РФ в рамках Государственного задания ФГБНУ «Федеральный научный агроинженерный центр ВИМ» (тема № FGUN-2025-0011).

Авторы благодарят рецензентов за их вклад в экспертную оценку этой работы.

Конфликт интересов: авторы заявили об отсутствии конфликта интересов.

Для цитирования: Кутырёв А. И., Филиппов Р. А. Применение компьютерного зрения и глубокого обучения для автоматизированного мониторинга роста растений земляники садовой. Аграрная наука Евро-Северо-Востока. 2026;27(2):480–492. DOI: <https://doi.org/10.30766/2072-9081.2026.27.2.480-492>

Поступила в редакцию: 15.05.2025

Принята к публикации: 13.03.2026

Доработана после рецензирования: 05.09.2025

Опубликована онлайн: 27.04.2026

Application of computer vision and deep learning for automated monitoring of garden strawberry plant growth

© 2026. Alexey I. Kutyrëv ✉, Rostislav A. Filippov

Federal Scientific Agroengineering Center VIM, Moscow, Russian Federation

The article presents the developed algorithm and software for automated monitoring of strawberry plant growth using neural network technologies. The YOLO11x and YOLOx-seg models, pre-trained by transfer learning, are adapted to recognize and classify plants (plant class), leaves (leaf class), and a reference marker (ref_obj class) of a known size. Segmentation of strawberry leaves using the YOLO11x-seg model makes it possible to analyze the morphometric parameters of individual leaf plates (area, perimeter, roundness, aspect ratio). A set of RGB images (2000 pieces) obtained using a GoPro HERO11 camera under controlled laboratory conditions was formed and annotated, followed by augmentation to increase the model's resistance to variations in shooting conditions. The developed algorithm converts the coordinates of the bounding boxes and segmentation

masks of recognized objects into metric units using calibration coefficients calculated from a marker of known size (100×100 mm). The software implemented using PyQt5, TensorFlow, Keras, and OpenCV libraries provides not only visualization of results but also data storage in a local SQLite database with the ability to export to JSON and Excel formats. Validation of the model showed high accuracy in detecting plant bounding boxes (mAP50 = 0.906) and leaf segmentation (mAP50-mask = 0.625). The average processing speed was 20.3 ms/frame for detection and 34.5 ms/frame for segmentation. The measurement error was less than 3.5 % for the overall parameters of the plant and 5.2 % for the morphometric parameters of the leaves, confirming the effectiveness of the method for assessing the height, width and area of plants, as well as the analysis of the leaf apparatus. The research results show the promise of an approach for automating plant phenotyping in real time.

Ключевые слова: machine learning, image processing, non-invasive monitoring, segmentation, neural network technologies

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-2025-0011).

The authors thank the reviewers for their contribution to the peer review of this work.

Conflict of interest: the authors stated that there was no conflict of interest.

For citations: Kutryev A. I., Filippov R. A. Application of computer vision and deep learning for automated monitoring of garden strawberry plant growth. *Agrarnaya nauka Evro-Severo-Vostoka = Agricultural Science Euro-North-East*. 2026;27(2):480–492. (In Russ.). DOI: <https://doi.org/10.30766/2072-9081.2026.27.2.480-492>

Received: 15.05.2025

Received after review: 05.09.2025

Accepted for publication: 13.03.2026

Published online: 27.04.2026

Земляника садовая (*Fragáaria × ananássa*) является одной из наиболее распространённых ягодных культур в мире, обладает высокой питательной ценностью и стабильным потребительским спросом. Благодаря своим уникальным вкусовым качествам и высокому содержанию витаминов и антиоксидантов, земляника садовая пользуется большой популярностью на мировом рынке [1]. По данным ФАО, мировое производство земляники ежегодно растёт, что подчеркивает её значимость в сельскохозяйственной отрасли¹.

Высокая продуктивность растений земляники садовой зависит не только от генетического потенциала сортов, но и правильно сформированного и своевременно проведённого комплекса оптимальных агротехнических мероприятий на всех этапах их развития [2]. Для достижения максимальной продуктивности и своевременного выявления отклонений в развитии растений необходим регулярный мониторинг вегетативных параметров роста растений [3].

Мониторинг развития надземной части растений земляники является важным этапом в селекционной работе при выведении новых сортов и сортоиспытаний, а также при исследовании влияния различных агротехнических приёмов, включая виды и дозы удобрений, корневые подкормки, регуляторы роста и средства защиты растений (СЗР). Детальный анализ динамики роста, морфологических характеристик, фенологических фаз и показателей продуктивности позволяет объективно оценить потенциал новых генотипов, выявить наиболее

перспективные гибридные формы и определять их адаптивность к различным условиям выращивания [4]. Ключевым параметром, определяющим фотосинтетический потенциал растений и его продуктивность, является скорость роста листьев земляники садовой. Листовой аппарат растений земляники садовой является основным органом фотосинтеза, при этом количество листьев, скорость их формирования и площадь листовой поверхности значительно варьируют в зависимости от сортовых особенностей, возраста растения и условий выращивания. Скорость роста листьев представляет собой интегральный показатель, комплексно отражающий состояние растения, характеризует фотосинтетический потенциал и эффективность светопоглощения, уровень обеспеченности питанием (азотом, микроэлементами и др.), является индикатором биотических стрессов, включая поражение патогенами, и абиотических факторов засоления, температурных изменений, а также эффективности применения регуляторов роста. В агротехнических исследованиях мониторинг развития надземной части растений земляники необходим при отслеживании изменений в росте, развитии листьев, формировании цветоносов и плодов, что позволяет оценить эффективность применяемых агрохимикатов и биологических препаратов, оптимизировать схемы подкормок и защиты растений. Информация, полученная в результате мониторинга, является основой для разработки научно обоснованных рекомендаций по применению агротехнических приёмов, обеспечивающих повышение урожайности и качества ягод [5].

¹Данные ФАО по производству земляники садовой. [Электронный ресурс].

URL: <https://www.fao.org/faostat/ru/#data/QCL/visualize> (дата обращения 10.02.2025).

Традиционные методы мониторинга заключаются в визуальной оценке общего состояния растений (размер и габитус куста, степень облиственности, окрас, форма, размер листьев, наличие признаков болезней и вредителей) и фенологических фаз (образование листьев, цветение, плодоношение, созревание ягод). Такой метод предполагает ручное измерение роста и развития надземной части растений с использованием простых измерительных инструментов, что характеризуется трудоёмкостью процесса, погрешностью сбора данных и значительными временными затратами, особенно на крупных участках.

Особое значение имеет разработка специализированного инструментария, позволяющего в автоматическом режиме оценивать площадь листовой поверхности и отслеживать динамику роста листового аппарата, что обеспечит высокую точность измерений, исключит субъективность ручных методов и позволит оперативно корректировать агротехнические мероприятия на основе объективных данных.

В современной науке и практике всё большее внимание уделяется технологиям компьютерного зрения и алгоритмам машинного обучения как перспективным инструментам автоматизированного мониторинга растений [6, 7]. В частности, системы компьютерного зрения (CV) активно внедряются в автоматизированное фенотипирование, обеспечивая неинвазивный и высокопроизводительный подход к отслеживанию динамики развития растений [8]. На основе анализа изображений, получаемых с использованием RGB, мультиспектральных и гиперспектральных камер, возможно получение объективных количественных характеристик, отражающих состояние растений [9, 10, 11]. Постоянный мониторинг развития растений, включающий учёт количества и площади листьев с помощью систем компьютерного зрения, обеспечивает возможность своевременного обнаружения изменений в фенологических фазах, что позволяет оперативно реагировать и нивелировать негативное действие стрессовых факторов [12].

Цель исследований – разработать алгоритм и программное обеспечение для неинвазивного мониторинга роста растений земляники с использованием нейросетевых технологий.

Научная новизна – разработаны алгоритм и программное обеспечение на основе нейросетевых технологий, обеспечивающие автоматизированный мониторинг роста растений земляники садовой, позволяя непрерывно отсле-

живать динамику ключевых параметров (высота, ширина, а также суммарная площадь листьев) в режиме реального времени.

Разработанное программное обеспечение предназначено для автоматизации этапа сбора и первичной обработки данных, что исключает субъективность ручных измерений и значительно повышает их производительность. Последующий анализ полученных данных и принятие агротехнических решений остаются за исследователем.

Материал и методы. Для мониторинга растений применяются различные методы обработки изображений (пороговая сегментация, выделение границ) [13, 14]. Методы машинного обучения (SVM, Random Forest) обеспечивают точность в контролируемых условиях, но требуют ручного выделения признаков, ограничивая адаптивность моделей [15, 16]. Методы на основе Vision Transformer (ViT) требуют значительный объем данных и вычислительных ресурсов, сложность архитектуры и большое количество параметров приводят к значительному увеличению времени обучения моделей [17].

Сравнительный анализ показывает, что алгоритмы машинного обучения на основе глубоких сверточных нейронных сетей (Convolutional Neural Network, CNN) являются одними из самых эффективных подходов для мониторинга растений. К таким алгоритмам относятся LeNet, AlexNet, VGG, GoogLeNet (Inception), ResNet, DenseNet, EfficientNet и другие [18, 19, 20]. Среди них семейство моделей YOLO (You Only Look Once), включая современную модель YOLO11, показывают наивысшую производительность в задачах мониторинга биологических объектов [21, 22]. Эти модели обеспечивают баланс между высокой точностью, скоростью работы и вычислительной эффективностью, что делает их наиболее подходящими для автоматизированного анализа изображений в сельском хозяйстве. Выбор моделей YOLO11x и YOLO11x-seg был основан на анализе данных с ресурса Computer Vision Model Leaderboard (<https://leaderboard.roboflow.com>), где модели показывают оптимальный баланс между точностью и скоростью для задач мониторинга. Компромисс между этими двумя критериями стал основным фактором выбора этих архитектур.

В исследовании применено трансферное обучение (transfer learning), при котором предварительно обученные на наборе данных COCO (Common Objects in Context) модели YOLO11x и YOLO11x-seg адаптированы

для распознавания объектов заданных классов на изображениях. Набор COCO содержит свыше 330 тысяч изображений с аннотациями более 2,5 миллионов объектов 80 классов.

Сбор данных, RGB-изображений земляники садовой (сорт Кабрилло) проводили в 2025 году в контролируемых лабораторных условиях с использованием камеры GoPro

HERO11, обеспечивающей высокое разрешение изображений (5,3К, 5312×2988 пикселей) и широкий угол обзора 155°. Съемку осуществляли на многоярусной установке, где в качестве грунта использовали кокосовый субстрат, что позволило контролировать освещенность (фитосветильник мощностью 60 Вт, световой поток 7500 Лм, цветовая температура 4500 К) (рис. 1).



Рис. 1. Сбор набора данных с использованием камеры GoPro HERO11 / Fig. 1. Dataset collection using a GoPro HERO11 camera

Камеру устанавливали на штативе Ulanzi OMBRA с регулируемой шаровой головкой на 360°, расстояние до объекта съемки варьировало от 0,3 до 0,6 м. Каждый снимок фиксировал растение земляники и эталонный маркер размером 100×100 мм. Съемка осуществлялась с нескольких ракурсов и под разными углами, что способствовало формированию вариативного набора данных, необходимого для обучения модели. Полученные изображения сохраняли в исходном качестве и перед обработкой проходили предварительную фильтрацию для исключения кадров с низкой четкостью.

Разметку данных выполняли с использованием платформы Roboflow. Загруженные на платформу изображения размечали и классифицировали на следующие типы объектов: растения (класс «plant»); листья (класс «leaf»); эталонный маркер (класс «ref_obj»). На каждом снимке проводилась ручная аннотация с выделением ограничивающих рамок (рис. 2) и масок сегментации (рис. 3) для определения координат объектов.

Дополнительная аугментация изображений, которая включала в себя вращение

изображений (Rotation 15°) и изменение яркости (Brightness 15°), позволила расширить выборку до 2000 шт. изображений и повысить устойчивость модели к вариациям условий съемки. Помимо вращения изображений и изменения яркости, на предварительном этапе было использовано отражение по горизонтали, масштабирование, изменение контраста и добавление шума. Тестирование показало, что указанные два метода аугментации дали наиболее стабильное улучшение обобщающей способности модели. Установлен баланс изображений с классами «plant», «leaf» и классом «ref_obj» 55 и 45 % соответственно. При этом 70 % изображений использовали для обучения, 15 % – для валидации и 15 % – для итогового тестирования. Изображения распределены по различным фазам развития (бутонизация 45 %, начало цветения 41 %, начало плодоношения 14 %) и условиям освещения (использовано искусственное освещение в контролируемых условиях). При обучении нейросетевой модели изображения масштабируют до разрешения 640×640 пикселей в соответствии с требованиями архитектуры YOLO11.

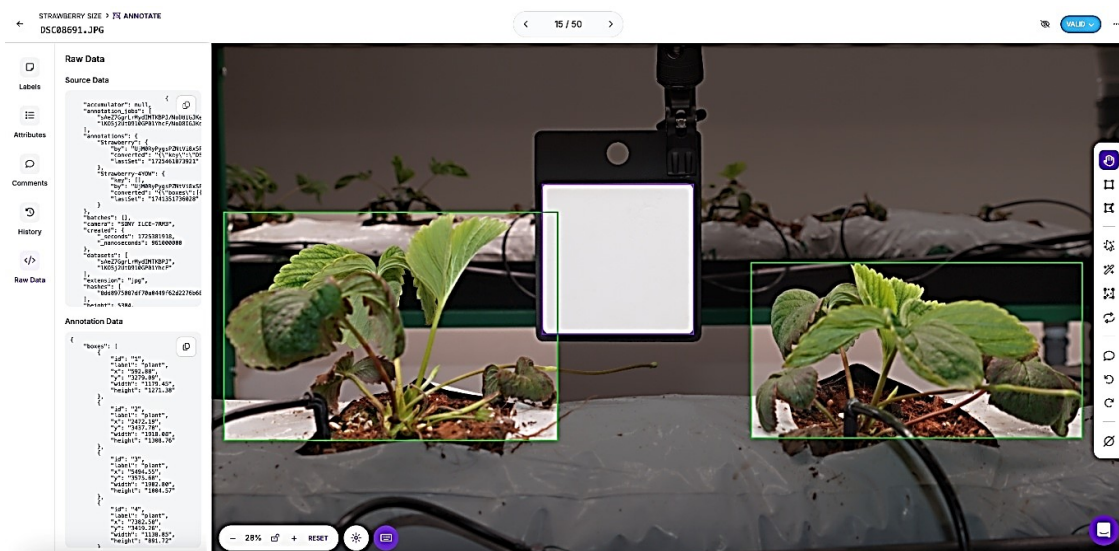


Рис. 2. Аннотация набора данных с выделением ограничивающих рамок (Bounding box) / Fig. 2. Dataset annotation with bounding box highlighting




Рис. 3. Аннотация набора данных с выделением масок сегментации (Mask) / Fig. 3. Dataset annotation with segmentation masks (Mask) highlighting

Метрики Precision и Recall использовали для оценки качества модели сверточной нейронной сети, определяя точность и полноту распознавания объектов как в процессе обучения, так и при тестировании на валидационных и тестовых наборах данных при распознавании ограничивающих рамок:

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

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

где TP_{Box} – количество верно обнаруженных ограничивающих рамок, FP_{Box} – количество ложноположительных ограничивающих рамок, FN_{Box} – количество ложноотрицательных ограничивающих рамок.

Средняя точность (метрика mAP) используется для оценки модели при различных порогах классификации:

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

где N – количество классов объектов, AP_{Box} – площадь под кривой точности-полноты (Precision-Recall curve) для каждого класса i при использовании ограничивающих рамок.

Оценка точности проведенной сегментации определялась с помощью метрики IoU (Intersection over Union):

$$\text{IoU} = \frac{\text{Area}_{\text{Intersection}}}{\text{Area}_{\text{Union}}}, \quad (4)$$

где $\text{Area}_{\text{Intersection}}$ – площадь пересечения между предсказанной маской (результат модели)

и истинной маской (ручная разметка), в пикселях, $Area_{Union}$ – площадь объединения предсказанной и истинной масок [23].

Метрика IoU оценивает точность совпадения масок, значение 1 означает идеальное совпадение, 0 – полное несовпадение.

Для оценки точности алгоритма при определении высоты, ширины и проекционной площади растений использовали эталонные ручные замеры линейкой (для линейных параметров) и анализ проекции на калиброванную

миллиметровую сетку (для площади). Валидация была проведена на отдельной тестовой выборке, состоящей из 100 изображений, не использовавшихся на этапах обучения и валидации модели.

Определение точности измерений площади листовых пластин с помощью алгоритма YOLO11x-seg проводили в сравнении с эталонными данными, полученными на лабораторном приборе LI-3100 AREA METER (рис. 4).




Рис. 4. Измерение площади поверхности листа земляники садовой на лабораторном приборе LI-3100 AREA METER /

Fig. 4. Measurement of garden strawberry leaf surface area using the laboratory instrument LI-3100 AREA METER

Было отобрано 50 листьев земляники садовой на различных стадиях развития. Для каждого листа получено RGB-изображение и проведено его измерение на приборе LI-3100. Образцы размещали на подвижной ленте прибора с минимальным шагом сканирования 1 мм² (для крупных листьев шириной до 10 см). Данные фиксировали программным обеспечением через USB-интерфейс.

В исследовании использовали программные библиотеки: CUDA 12.2 для параллельных вычислений на GPU; TensorFlow 2.15.0 и Keras 2.15.0 – для обучения нейронной сети; TensorBoard 2.15.0 – для визуализации процесса обучения; PyArrow 10.0.1 – для обработки больших объемов данных; JAX 0.4.23 и JAXLib 0.4.23 – для численных расчетов с автоматическим дифференцированием. Кроме того, применяли NumPy для работы с многомерными массивами и математическими функциями, OpenCV – для задач компьютерного зрения,

Pillow – для обработки изображений, matplotlib – для визуализации данных, PyQt5 – для создания графического интерфейса, для локального хранения результатов – база данных SQLite. Обучение моделей проводили на компьютере с центральным процессором Intel Core i9-10900X (10 ядер, 3.7 ГГц), оперативная память (RAM) 64 ГБ DDR4, высокоскоростной SSD-накопитель емкостью 1 ТБ, использованы 2 видеокарты NVIDIA GeForce RTX 2080 TI с памятью 11 ГБ GDDR6.

Результаты и их обсуждение. Обучение моделей YOLO11x и YOLO11x-seg, включающих 464 слоя и 56,8 млн параметров (194,4 GFLOPs) и 295 слоев 62,1 млн параметров (319,0 GFLOPs) соответственно, проводили с максимальным числом эпох 500, однако благодаря ранней остановке (patience = 100) процесс обучения завершился на 336-й эпохе (10,52 часа) для YOLO11x и 307-й эпохе (10,52 часа) для YOLO11x-seg. Предварительно обученные

модели YOLO11 оптимизированы с начальными параметрами $lr0 = 0,01$ (скорость обучения), $momentum = 0,937$ (инерция градиентного спуска), $weight_decay = 0,0005$ (регуляризация), с выбором оптимизатора «auto» (автоматический подбор) и задействованием 8 рабочих потоков (ускорение загрузки данных). При валидации модели YOLO11x на выборке из 300 изображений средняя точность (Box(P)) по всем классам составила 0,91, а средняя полнота (Mask(R)) = 0,93, при этом для класса «plant» значение Box(P) достигло 0,906, а класса «ref_obj» – 0,989; в свою очередь, модель YOLO11x-seg показала среднюю точность сегментации (Mask(P)) 0,802 и полноту (Mask(R)) 0,766 по всем классам с отдельными значениями Mask(P) для класса «leaf» – 0,625 и «ref_obj» – 0,968. Среднее время распознавания заданных классов на изображении моделью YOLO11x составило 20,3 мс/кадр, моделью YOLO11x-seg – 34,5 мс/кадр.

Разработанный алгоритм оценки размеров растения и анализа морфометрических параметров отдельных листовых пластин основывается на последовательном преобразовании данных (изображений), полученных от моделей YOLO11x и YOLO11x-seg, в физические параметры с использованием калибровочных коэффициентов, что обеспечивает переход от пиксельных координат к метрическим единицам измерения (рис. 5).

На первом этапе, после загрузки изображения, проводится распознавание ограничивающих рамок и масок сегментации для заданных классов («plant», «ref_obj», «leaf») и эталонного маркера известного размера (100x100 мм), который используется для определения масштаба изображения. При распознавании все исходные изображения с разрешением 5312x2988 пикселей предварительно приводятся к разрешению 1920x1080 пикселей. Модель YOLO11x возвращает координаты углов каждой рамки в формате $[x_1, y_1, x_2, y_2]$, (x_1, y_1) – левый верхний угол, (x_2, y_2) – правый нижний угол и бинарные маски сегментации для объектов класса «plant» и «leaf» в формате матрицы $[H \times W]$, где H и W – высота и ширина изображения. Значение 1 в матрице соответствует пикселям объекта, 0 – фону.

Координаты рамок и масок извлекаются из выходных данных модели для обоих объектов, что соответствует математическому представлению вектора:

$$B_i = [x_1^{(i)}, y_1^{(i)}, x_2^{(i)}, y_2^{(i)}], \quad (5)$$

где $i \in \{plant, ref\}$.

На втором этапе для растения рассчитываются высота и ширина как разность между соответствующими координатами рамки по формулам:

$$H_{plant}^{px} = y_2^{plant} - y_1^{plant}, \quad (6)$$

$$W_{plant}^{px} = x_2^{plant} - x_1^{plant}, \quad (7)$$

где y_2^{plant} и y_1^{plant} – вертикальные координаты (в пикселях) нижнего и верхнего краев рамки растения соответственно, x_2^{plant} и x_1^{plant} – горизонтальные координаты правого и левого краёв рамки растения соответственно.

Аналогично для эталонного объекта вычисляется его высота в пикселях, которая в дальнейшем используется для определения масштаба изображения.

Для масок сегментации листьев дополнительно вычисляется площадь по формуле:

$$A_{leaf}^{px} = \sum_{(x,y)} M(x,y), \quad (8)$$

где $M(x,y)$ – значение маски (0 или 1) в координате (x, y) .

Границы маски для расчёта периметра определяются с использованием алгоритма выделения контуров.

Третий этап заключается в переводе пиксельных размеров в сантиметры с использованием эталонного объекта. Поскольку физический размер эталона известен, коэффициент преобразования (k_{conv}) рассчитывается как отношение эталонной высоты в миллиметрах к её высоте в пикселях:

$$k_{conv} = \frac{H_{ref}^{true}}{H_{ref}^{px}}, \quad (9)$$

где H_{ref}^{true} – известный физический размер эталонного объекта, мм; H_{ref}^{px} – высота эталонного объекта в пикселях, вычисленная как разность между координатами.

Четвертый этап включает в себя калибровку результатов для учёта возможных погрешностей, вызванных перспективными искажениями или неточностями модели. Пользователь может вручную задать калибровочный коэффициент (k_{calib}) через интерфейс или он вычисляется автоматически (функция «auto_calibrate»), при этом автокалибровка сравнивает расчетный размер эталона ($H_{ref}^{cm} = H_{ref}^{px} \cdot k_{conv}$) с его истинным размером (H_{ref}^{true}) и корректирует коэффициент. Это позволяет компенсировать систематические ошибки, например, если модель ошибочно определила размер эталона.

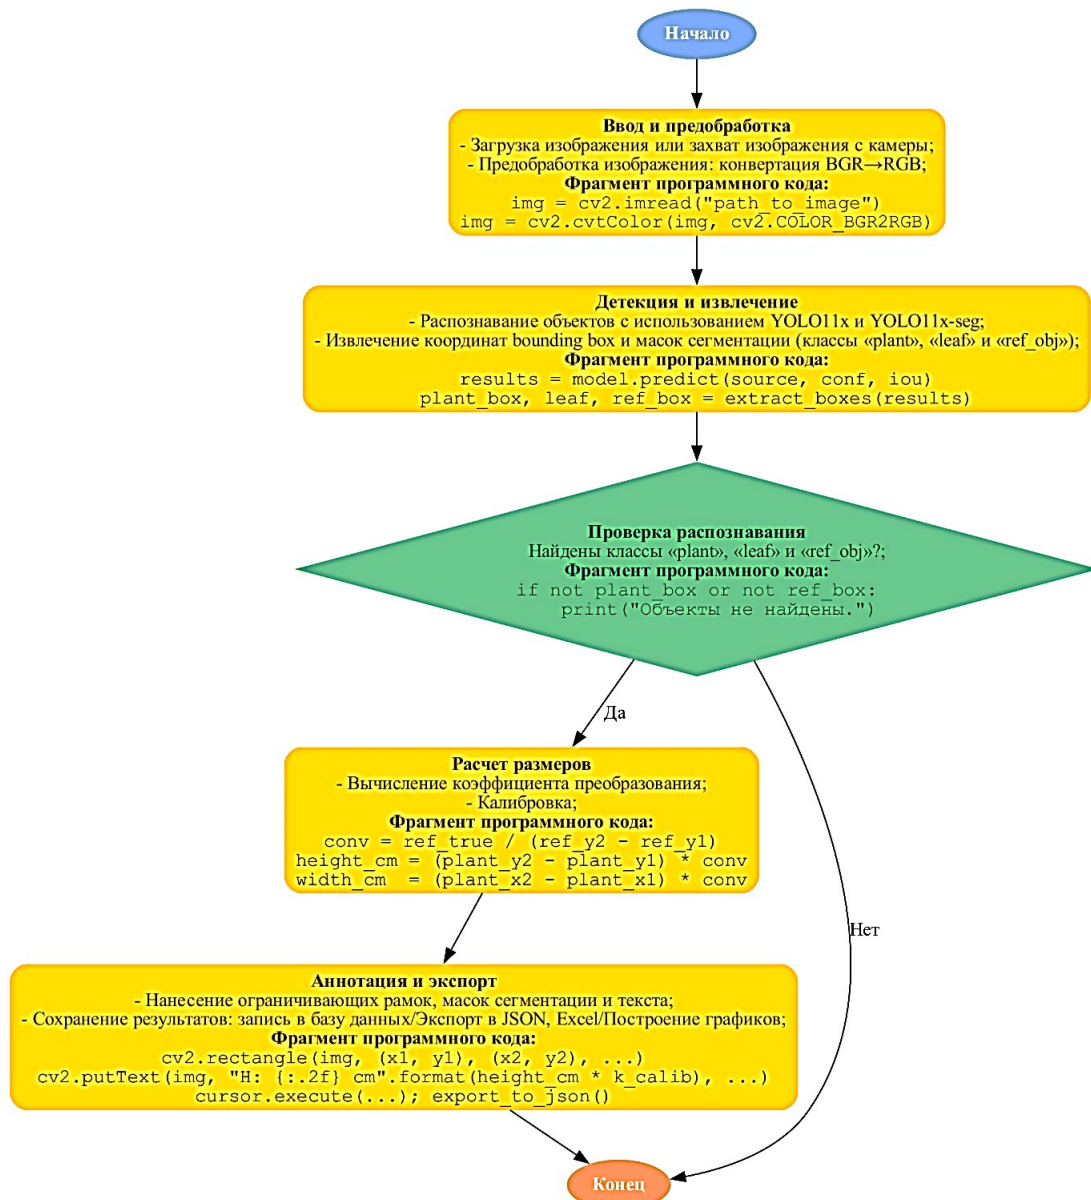


Рис. 5. Алгоритм распознавания земляники садовой и оценки размеров растения с использованием нейросетевых технологий /

Fig. 5. Algorithm for garden strawberry recognition and plant size estimation using neural network technologies

Пятый этап включает в себя применение калибровочного коэффициента к размерам растения. Калиброванная высота и ширина вычисляются умножением исходных значений на k_{calib} . Площадь растения рассчитывается как произведение калиброванных высоты и ширины, но для минимизации погрешностей сначала вычисляется площадь в пикселях, которая затем масштабируется с учётом коэффициентов преобразования и калибровки по формулам:

$$A_{plant}^{px} = H_{plant}^{px} \cdot W_{plant}^{px}, \quad (10)$$

$$A_{plant}^{cm} = A_{plant}^{px} \cdot (k_{conv} \cdot k_{calib})^2. \quad (11)$$

Периметр листа определяется:

$$P_{leaf} = N_{boundary} \cdot k_{conv} \cdot k_{calib}, \quad (12)$$

где $N_{boundary}$ – суммарное количество пикселей, через которые проходит граница листа, пикс.

Коэффициент округлости листьев вычисляется по формуле:

$$C_{leaf} = \frac{4\pi \cdot A_{leaf}^{cm}}{(P_{leaf})^2}. \quad (13)$$

Итоговые параметры (высота, ширина, площадь) накладываются на исходное изображение, выводятся в интерфейсе и сохраняются в локальную базу данных (SQLite) вместе с меткой времени и уверенностью (confidence) модели, что позволяет проводить последующий анализ данных.

Разработанное программное обеспечение осуществляет автоматизированный учёт морфометрических характеристик листового аппарата растений путём присвоения каждой листовой пластине уникального идентификационного номера (ID) с последующей фиксацией в базе данных количественных параметров, количество листовых пластин и их площадь, коэффициент округлости, соотношение сторон, длину периметра, угол наклона и другие параметры. Система реализует как индивидуальный анализ морфологических признаков на уровне отдель-

ного листа, так и общую статистическую обработку данных для всей совокупности листьев, включая расчет суммарных площадей, средних значений и стандартных отклонений измеряемых показателей. Разработанный графический интерфейс с использованием библиотеки PyQt5 позволяет пользователю как загружать изображение из файла, так и получать его с камеры в реальном времени для дальнейшей обработки изображений, выделения ограничивающих рамок (рис. 6) и сегментации листовых пластин (рис. 7).

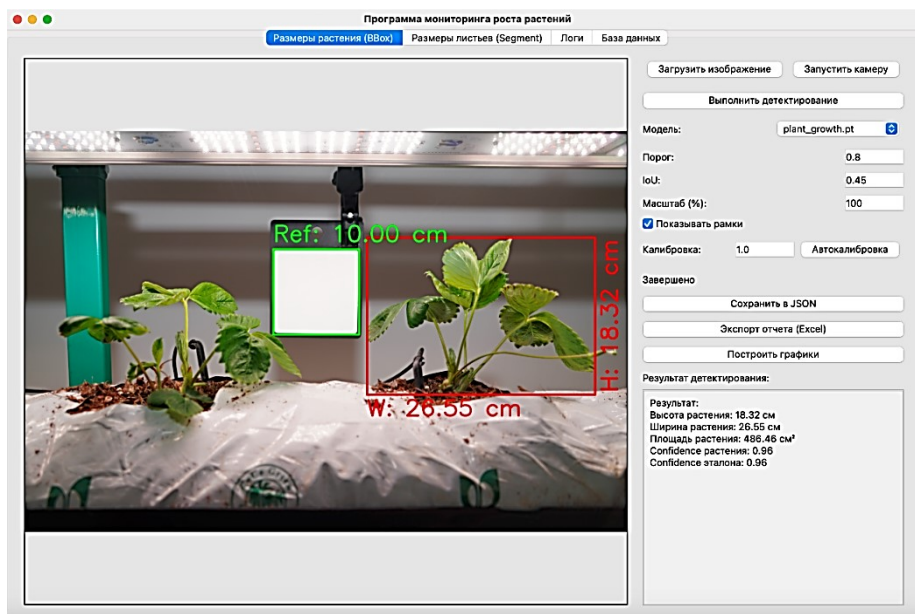


Рис. 6. Интерфейс программного обеспечения для анализа параметров роста растений земляники садовой / Fig. 6. Software interface for analyzing growth parameters of garden strawberry plants

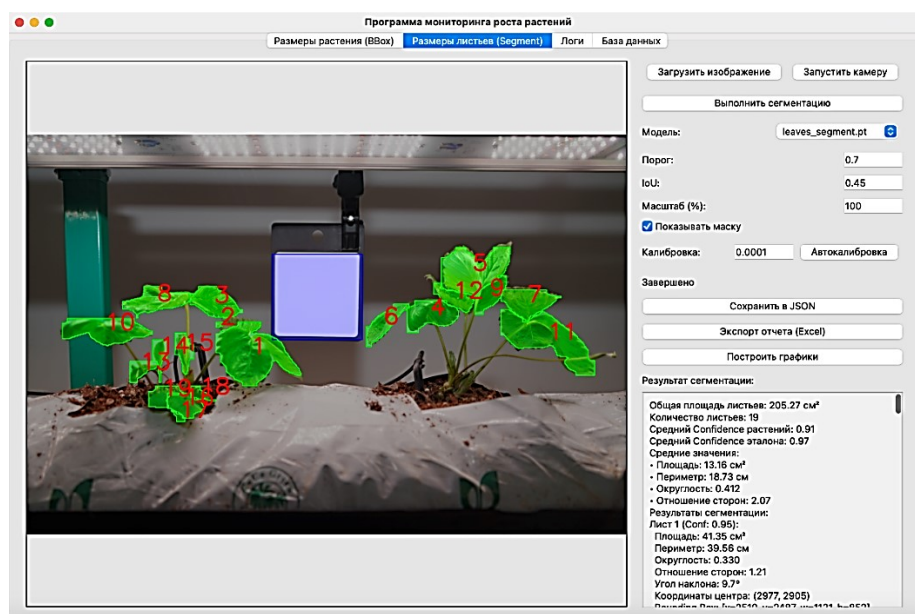


Рис. 7. Интерфейс программного обеспечения для анализа морфометрических характеристик листового аппарата растений земляники садовой / Fig. 7. Software interface for analyzing morphometric characteristics of the leaf apparatus in garden strawberry plants

Предусмотрены функции экспорта данных в форматы JSON и Excel, а также построение графиков динамики изменения параметров растения с использованием библиотеки matplotlib.

На рисунках 8 и 9 представлены графики результатов мониторинга роста растения земляники садовой и изменения средней площади листовой поверхности в течение 35 дней.

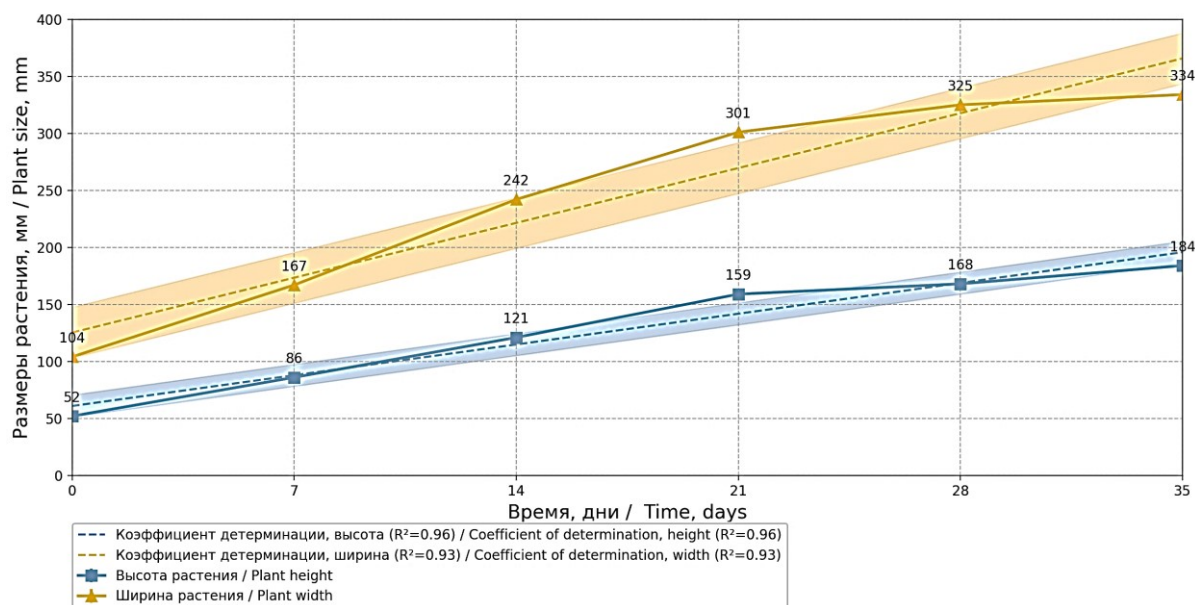


Рис. 8. График динамики изменения роста (ширина, высота ограничивающей рамки) растения / Fig. 8. Graph of plant growth dynamics (width, height of the bounding box)

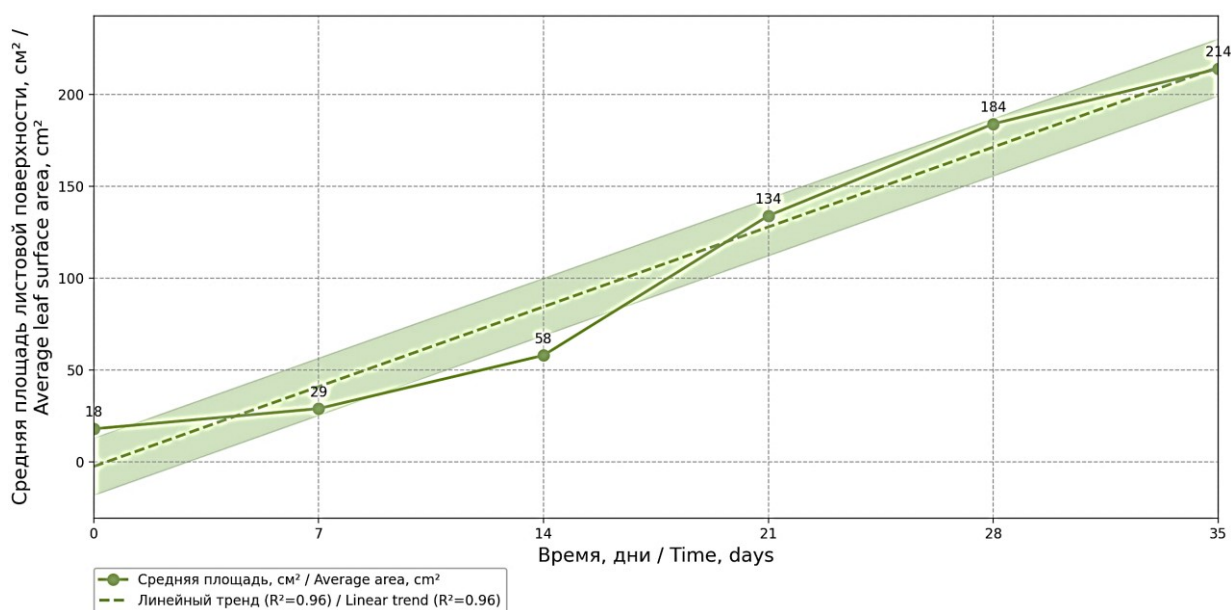


Рис. 9. График динамики изменения средней площади листовой поверхности растения (сегментация листьев) / Fig. 9. Graph of dynamics in the average leaf surface area of the plant (leaf segmentation)

Для анализа динамики роста проведена линейная аппроксимация, результаты которой представлены пунктирными линиями. Коэффициенты детерминации $R^2 = 0,96$ для высоты и $R^2 = 0,93$ для ширины указывают на высокую

степень линейной зависимости между временем наблюдения и размерами растения. Замедление прироста высоты после 21-го дня (с 3,8 мм/день в период первых 21 дня до 2,1 мм/день в последние две недели) коррелирует с переходом растения

к фазе бутонизации, что согласуется с биологическими особенностями культуры. Ширина растения показывает более стабильный прирост (в среднем 3,4 мм/день), что может быть связано с активным формированием розетки листьев.

Незначительное отклонение от линейного тренда динамики изменения средней площади листовой поверхности растения в начальный период (первые 7 дней) отражает адаптационную фазу, после которой скорость прироста площади стабилизируется. Полученные данные согласуются с типичными закономерностями роста культур в контролируемых условиях.

Серия тестов показала, что погрешность определения габаритных характеристик (высота, ширина, проекционная площадь растения) не превышает 3,5 %. Высокая точность измерений и низкая погрешность позволяют использовать предложенный алгоритм для автоматизированного мониторинга роста растений в контролируемых условиях. Ложноположительные срабатывания модели (false positives) наблюдали при фоновом шуме, ложноотрицательные срабатывания модели (false negatives) – в случаях частичного перекрытия объектов. Порог уверенности (confidence threshold) был оптимизирован в ходе экспериментов и установлен на уровне 0,54, что обеспечило оптимальный баланс между скоростью и точностью.

Сравнительный анализ результатов измерений показал, что разработанный алгоритм сегментации обеспечивает погрешность менее 5,2 % при определении площади отдельных листовых пластин по сравнению с эталонным методом. Также было изучено влияние перспективных искажений, возникающих при съёмке под различными углами, и определено, что при отклонении камеры более чем на 15° от перпендикуляра наблюдается увеличение ошибки на 1-2 %. Для компенсации ошибки предусмотрена возможность корректировки калибровочного коэффициента в интерфейсе программы.

Разработанный программный код реализует полный цикл обработки от детектирования объектов до анализа и визуализации. Пользователь может настраивать такие параметры, как порог уверенности (confidence threshold), пересечение ограничивающих рамок IoU (Intersection over Union) и масштаб изображения, что позволяет адаптировать работу моделей YOLO11 под различные условия съёмки и повысить точность детекции. Перспективы дальнейших исследований включают интег-

рацию лидарных данных с моделью сверточной нейронной сети YOLO11 [24], что позволит повысить точность измерений за счет получения информации о трехмерной структуре растений.

Текущая реализация системы решает задачу точного и автоматизированного измерения параметров в условиях закрытого грунта, что является основным этапом мониторинга. Система позволяет отслеживать изменения одного и того же растения в условиях закрытого грунта с жёстко закреплёнными камерами и эталонными маркерами, которые служат не только для калибровки, но и для привязки к конкретной точке съёмки. Для применения в полевых условиях, где присутствуют вариации освещённости, фона, углов съёмки и возможны перемещения камеры, требуются дополнительные алгоритмы. Перспективным направлением является использование методов трекинга (например, Simple Online and Realtime Tracking, SORT или DeepSORT) для отслеживания растений по их местоположению между последовательными кадрами видео или отдельными снимками. Для работы в условиях изменяющегося естественного освещения и сложного фона необходим сбор дополнительного обширного датасета и дообучение моделей на таких данных, а также использование методов аугментации, имитирующих эти условия (наложение случайных теней, изменение цветового баланса, симуляция различных погодных условий).

Заключение. Разработанное программное обеспечение позволяет автоматизировать процесс высокоточного измерения ключевых морфометрических параметров растений земляники садовой (высота, ширина, площадь листьев). Использование разработанного алгоритма позволяет проводить оценку влияния агротехнических приёмов в режиме реального времени за счёт высокой скорости обработки данных и низкой погрешности измерений, исключая субъективность, свойственную визуальным оценкам. Особую ценность представляет возможность отслеживания динамики роста отдельных листьев, что важно для ранней диагностики стрессовых состояний и оценки эффективности подкормок.

Программное обеспечение позволяет проводить сбор данных в течение нескольких вегетационных сезонов с сохранением результатов в базе данных для дальнейшего построения высокоточных прогнозных моделей динамики роста и развития растений. Применение сверточных нейронных сетей позволит проводить

детальную количественную оценку влияния разнообразных факторов (изменений освещенности, температуры, влажности и состава питательного раствора и др.) на рост растений. Разработанное программное обеспечение

создаёт предпосылки для его внедрения в селекционные исследования и сортоиспытания, направленные на оптимизацию агротехнических мероприятий для повышения продуктивности земляники садовой.

References

1. Ожерельев В. Н., Ожерельева М. В., Гринь А. М., Сомин В. В. Динамика производства ягод земляники садовой по странам мира. Вестник Брянской государственной сельскохозяйственной академии. 2019;(4(74)):60–66. Режим доступа: <https://elibrary.ru/item.asp?id=39174971> EDN: EMFTKC
Ozherelev V. N., Ozhereleva M. V., Grin A. M., Somin V. V. Dynamics of garden strawberries production all over the world. *Vestnik Bryanskoy gosudarstvennoy sel'skokhozyaystvennoy akademii* = Vestnik of the Bryansk State Agricultural Academy. 2019;(4(74)):60–66. (In Russ.). URL: <https://elibrary.ru/item.asp?id=39174971>
2. Марченко Л. А. Продуктивность земляники садовой и селекционные возможности ее повышения. Сибирский вестник сельскохозяйственной науки. 2021;51(3):65–74. DOI: <https://doi.org/10.26898/0370-8799-2021-3-7> EDN: XRWZRZ
Marchenko L. A. Productivity of garden strawberry and breeding possibilities to improve it. *Sibirskiy vestnik sel'skokhozyaystvennoy nauki* = Siberian Herald of Agricultural Science. 2021;51(3):65–74. (In Russ.). DOI: <https://doi.org/10.26898/0370-8799-2021-3-7>
3. Guan Z., Abd-Elrahman A., Fan Z., Whitaker V. M., Wilkinson B. Modeling strawberry biomass and leaf area using object-based analysis of high-resolution images. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2020;163:171–186. DOI: <https://doi.org/10.1016/j.isprsjprs.2020.02.021>
4. Марченко Л. А., Акимова С. В., Соловьев А. В., Макаров С. С., Самощенко Е. Г., Тер-Петросянц Г. Э., Зубков А. В. Роль минеральных элементов в питании растений земляники садовой. Овощи России. 2024;(5):79–83. DOI: <https://doi.org/10.18619/2072-9146-2024-5-79-83> EDN: PXIWHJ
Marchenko L. A., Akimova S. V., Solovyov A. V., Makarov S. S., Samoshenkov E. G., Ter-Petrosyants G. E., Zubkov A. V. Role of mineral elements in the nutrition of garden strawberry plants. *Ovoshchi Rossii* = Vegetable crops of Russia. 2024;(5):79–83. (In Russ.). DOI: <https://doi.org/10.18619/2072-9146-2024-5-79-83>
5. Haida M., El Khalloufi F., Mugani R., Redouane E. M., Campos A., Vasconcelos V., Oudra B. Effects of Irrigation with Microcystin-Containing Water on Growth, Physiology, and Antioxidant Defense in Strawberry *Fragaria vulgaris* under Hydroponic Culture. *Toxins*. 2022;14(3):198 DOI: <https://doi.org/10.3390/toxins14030198>
6. Mi Z., Yan W. Q. Strawberry Ripeness Detection Using Deep Learning Models. *Big Data and Cognitive Computing*. 2024;8(8):92. DOI: <https://doi.org/10.3390/bdcc8080092>
7. Хорт Д. О., Кутырев А. И., Смирнов И. Г., Воронков И. В. Разработка системы автоматизированного управления агротехнологиями в садоводстве. Сельскохозяйственные машины и технологии. 2021;15(2):61–68. DOI: <https://doi.org/10.22314/2073-7599-2021-15-2-61-68> EDN: AQNSNT
Khort D. O., Kutyrev A. I., Smirnov I. G., Voronkov I. V. Development of an Automated Management System for Agricultural Technologies in Horticulture. *Sel'skokhozyaystvennyye mashiny i tekhnologii* = Agricultural Machinery and Technologies. 2021;15(2):61–68. (In Russ.). DOI: <https://doi.org/10.22314/2073-7599-2021-15-2-61-68>
8. Zhang Y., Zhang L., Yu H., Guo Z., Zhang R., Zhou X. Research on the Strawberry Recognition Algorithm Based on Deep Learning. *Applied Sciences*. 2023;13(20):11298. DOI: <https://doi.org/10.3390/app132011298>
9. Shurygin B., Smirnov I. G., Chilikin A., Khort D. O., Kutyrev A. I., Zhukovskaya S., Solovchenko A. Mutual augmentation of spectral sensing and machine learning for non-invasive detection of apple fruit damages. *Horticulturae*. 2022;8(12):1111. DOI: <https://doi.org/10.3390/horticulturae8121111>
10. Khort D. O., Kutyrev A., Smirnov I., Andriyanov N., Filippov R., Chilikin A. et al. Enhancing sustainable automated fruit sorting: hyperspectral analysis and machine learning algorithms. *Sustainability*. 2024;16(22):10084. DOI: <https://doi.org/10.3390/su162210084>
11. 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;67(1(38)):133–141. DOI: <https://doi.org/10.22314/2658-4859-2020-67-1-133-141> EDN: BYNXCB
Khort D. O., Kutyrev A. I., Smirnov I. G., Filippov R. A., Vershinin R. V. Razrabotka algoritmov sistemy raspoznavaniya yagod zemlyani-niki sadovoy pri robotizirovannom sbore. *Elektrotekhnologii i elektrooborudovanie v APK*. 2020;67(1(38)):133–141. (In Russ.). DOI: <https://doi.org/10.22314/2658-4859-2020-67-1-133-141>
12. Xie D., Yao W., Sun W., Song Z. Real-Time Identification of Strawberry Pests and Diseases Using an Improved YOLOv8 Algorithm. *Symmetry*. 2024;16(10):1280. DOI: <https://doi.org/10.3390/sym16101280>
13. Yang J.-W., Kim H.-I. An Overview of Recent Advances in Greenhouse Strawberry Cultivation Using Deep Learning Techniques: A Review for Strawberry Practitioners. *Agronomy*. 2024;14(1):34. DOI: <https://doi.org/10.3390/agronomy14010034>

14. Jovanović R., Djordjevic A., Stefanovic M., Eric M., Pajić N. Enhanced Defect Management in Strawberry Processing Using Machine Vision: A Cost-Effective Edge Device Solution for Real-Time Detection and Quality Improvement. *Applied Sciences*. 2024;14(17):7771. DOI: <https://doi.org/10.3390/app14177771>
15. Fan L., Yu J., Zhang P., Xie M. Prediction of Strawberry Quality during Maturity Based on Hyperspectral Technology. *Agronomy*. 2024;14(7):1450. DOI: <https://doi.org/10.3390/agronomy14071450>
16. Basak J. K., Paudel B., Kim N. E., Deb N. C. Kaushalya Madhavi B. G., Kim H. T. Non-Destructive Estimation of Fruit Weight of Strawberry Using Machine Learning Models. *Agronomy*. 2022;12(10):2487. DOI: <https://doi.org/10.3390/agronomy12102487>
17. Christakakis P., Giakoumoglou N., Kapetas D., Tzovaras D., Pechlivani E.-M. Vision Transformers in Optimization of AI-Based Early Detection of Botrytis cinerea. *AI*. 2024;5(3):1301–1323. DOI: <https://doi.org/10.3390/ai5030063>
18. Xiao J.-R., Chung P.-C., Wu H.-Y., Phan Q.-H., Yeh J.-L.A., Hou M.T.-K. Detection of Strawberry Diseases Using a Convolutional Neural Network. *Plants*. 2021;10(1):31. DOI: <https://doi.org/10.3390/plants10010031>
19. Kesler S., Karakan A., Oğuz Y. Real-Time Strawberry Plant Classification and Efficiency Increase with Hybrid System Deep Learning: Microcontroller and Mobile Application. *Applied Sciences*. 2022;12(17):8860. DOI: <https://doi.org/10.3390/app12178860>
20. Kim H., Kim D. Deep-Learning-Based Strawberry Leaf Pest Classification for Sustainable Smart Farms. *Sustainability*. 2023;15(10):7931. DOI: <https://doi.org/10.3390/su15107931>
21. Wang C., Wang H., Han Q., Zhang Z., Kong D., Zou X. Strawberry Detection and Ripeness Classification Using YOLOv8+ Model and Image Processing Method. *Agriculture*. 2024;14(5):751. DOI: <https://doi.org/10.3390/agriculture14050751>
22. Chen Y., Xu H., Chang P., Huang Y., Zhong F., Jia Q. et al. CES-YOLOv8: Strawberry Maturity Detection Based on the Improved YOLOv8. *Agronomy*. 2024;14(7):1353. DOI: <https://doi.org/10.3390/agronomy14071353>
23. Maxwell A. E., Warner T. A., Guillén L. A. Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies - Part 1: Literature Review. *Remote Sensing*. 2021;13(13):2450. DOI: <https://doi.org/10.3390/rs13132450>
24. Saha K. K., Tsoulias N., Weltzien C., Zude-Sasse M. Estimation of Vegetative Growth in Strawberry Plants Using Mobile LiDAR Laser Scanner. *Horticulturae*. 2022;8(2):90. DOI: <https://doi.org/10.3390/horticulturae8020090>

Вклад авторов:

Авторы внесли равноценный вклад в подготовку публикации.

Сведения об авторах

✉ **Кутырёв Алексей Игоревич**, кандидат техн. наук, заведующий лабораторией интеллектуальных цифровых систем мониторинга, диагностики и управления процессами в сельскохозяйственном производстве, ведущий научный сотрудник, ФГБНУ «Федеральный научный агроинженерный центр ВИМ», 1-й Институтский проезд, д. 5, г. Москва, Российская Федерация, e-mail: vim@vim.ru, ORCID: <https://orcid.org/0000-0001-7643-775X>, e-mail: alexeykutyrev@gmail.com

Филиппов Ростислав Александрович, кандидат с.-х. наук, ведущий научный сотрудник, ФГБНУ «Федеральный научный агроинженерный центр ВИМ», 1-й Институтский проезд, д.5, г. Москва, Российская Федерация, e-mail: vim@vim.ru, ORCID: <https://orcid.org/0000-0003-3586-3634>

Author Contributions:

The authors contributed equally to the preparation of this publication.

Information about the authors

✉ **Alexey I. Kutyrev**, PhD in Engineering, Head of the Laboratory of Intelligent Digital Systems for Monitoring, Diagnostics and Process Management in Agricultural Production, leading researcher, Federal Scientific Agroengineering Center VIM, 1st Institute passage, 5, Moscow, Russian Federation, e-mail: vim@vim.ru, ORCID: <https://orcid.org/0000-0001-7643-775X>, e-mail: alexeykutyrev@gmail.com

Rostislav A. Filippov, PhD in Agricultural Science, leading researcher, Federal Scientific Agroengineering Center VIM, 1st Institute passage, 5, Moscow, Russian Federation, e-mail: vim@vim.ru, ORCID: <https://orcid.org/0000-0003-3586-3634>

✉ – Для контактов / Corresponding author