

РАЗРАБОТКА АВТОМАТИЗИРОВАННОГО МЕТОДА ПРОГНОЗИРОВАНИЯ УРОЖАЙНОСТИ ЗЕМЛЯНИКИ САДОВОЙ С ИСПОЛЬЗОВАНИЕМ БЛА И АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

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

Федеральный научный агроинженерный центр ВИМ
(г. Москва, Российская Федерация)
✉ alexeykutyrev@gmail.com

Реферат. В статье представлен метод дистанционного мониторинга и прогнозирования урожайности земляники садовой (*Fragaria × ananassa*), основанный на применении беспилотных летательных аппаратов (БЛА), технологий компьютерного зрения и глубокого обучения. Использование морфологических особенностей культуры, обеспечивает высокую точность детекции с БЛА. Исследование проводилось с использованием сверточной нейронной сети YOLO12 версия Extra Large, обученной методом трансферного обучения (Transfer Learning) на специализированном датасете изображений цветков земляники садовой (класс "Flower"). Датасет создан путем ручной разметки в программе RectLabel и расширен до 1700 изображений (18496 экземпляров) с помощью комплексной аугментации данных. Сбор исходных данных осуществлялся с помощью БЛА DJI Mavic 3M (RGB-камера) на высоте 30-60 м. Обработка снимков включала построение высокоточного ортофотоплана (разрешение 0,570 мм/пиксель) в программе Agisoft Metashape Pro. Для детекции ортофотоплан автоматически разбивался на фрагменты 200×200 пикселей. Обучение модели YOLO12 (гиперпараметры: batch size=8, learning rate=0.001, эпохи=1500) достигло высоких метрик на тестовой выборке: точность (Precision) 0,903, полнота (Recall) 0,812, F-мера 0,852, mAP50 0,888. На основе разработанного метода создано специализированное программное обеспечение с графическим интерфейсом, реализующее полный цикл обработки: разбиение ортофотоплана на плитки, детекцию цветков, объединение результатов детекции в единый ортофотоплан, пространственный анализ (построение тепловых карт плотности, расчет индекса Морана для оценки кластеризации, кластерный анализ K-means, визуализация диаграмм Вороного) и прогнозирование урожайности по формуле, учитывающей количество распознанных цветков, сортовые коэффициенты преобразования и средний вес ягоды. Применение метода позволяет автоматизировать подсчет цветков на больших площадях, выявлять зоны неоднородной продуктивности, прогнозировать урожайность на ранних стадиях вегетации, существенно сокращая трудозатраты и обеспечивая основу для принятия агротехнических решений.

Ключевые слова: сверточные нейронные сети, трансферное обучение, обработка изображений, мониторинг, прогнозирование урожайности, точное земледелие.

Для цитирования: Кутырёв А.И., Филиппов Р.А. Разработка автоматизированного метода прогнозирования урожайности земляники садовой с использованием БЛА и алгоритмов машинного обучения // Вестник Казанского государственного аграрного университета. 2026. Т. 21. № 1(81). С. 69-78. doi: 10.31588/2073-0462-2026-21-1-69-78

DEVELOPMENT OF AN AUTOMATED METHOD FOR FORECASTING STRAWBERRY YIELD USING UAVS AND MACHINE LEARNING ALGORITHMS

© 2026 Kutyrev A. I. ✉, Filippov R. A.

Federal Scientific Agroengineering Center VIM
(Moscow, Russian Federation)
✉ alexeykutyrev@gmail.com

Abstract. This article presents a method for remote monitoring and forecasting of strawberry (*Fragaria × ananassa*) yields based on unmanned aerial vehicles (UAVs), computer vision and deep learning technologies. Using morphological features of the crop, UAVs ensure high detection accuracy. The study was conducted using YOLO12 Extra Large convolutional neural network, trained using transfer learning on a specialized dataset of strawberry flower images (class "Flower"). The dataset was created by manual labeling in RectLabel and expanded to 1700 images (18 496 exemplars) using complex data augmentation. Initial data were collected using a DJI Mavic 3M UAV (RGB camera) at an altitude of 30-60 m. Image processing included the construction of a high-precision orthomosaic (resolution 0.570 mm/pixel) in Agisoft Metashape Pro. Orthomosaic was automatically divided into 200×200 pixel fragments for detection. Training YOLO12 model (hyperparameters: batch size = 8, learning rate = 0.001, epochs = 1500) achieved high metrics on the test set: precision 0.903, recall 0.812, F-measure 0.852, mAP50 0.888. Based on the developed method, specialized software with a graphical interface was created. It implements the full processing cycle: orthomosaic tiling, flower detection, merging detection results into a single orthomosaic, spatial analysis (construction of density heat maps,

calculation of Moran's index for clustering assessment, K-means cluster analysis, visualization of Voronoy diagrams), and yield forecasting using a formula that takes into account the number of recognized flowers, varietal conversion factors and average berry weight. The method enables automated flower counting over large areas, identification of zones of uneven productivity and yield forecasting in the early stages of vegetation, significantly reducing labor costs and providing a basis for making agricultural decisions.

Key words: convolutional neural networks, transfer learning, image processing, monitoring, yield forecasting, precision farming.

For citation: Kuttyrev AI, Filippov RA. [Development of an automated method for forecasting strawberry yield using UAVs and machine learning algorithms]. Vestnik of Kazan State Agrarian University. 2026; Vol. 21. 1(81). 69-78 p. doi: 10.31588/2073-0462-2026-21-1-69-78

Введение. Земляника садовая (*Fragaria × ananassa*) занимает лидирующие позиции в мировом ягодном производстве благодаря высокой урожайности, отличным вкусовым качествам и относительной неприхотливости при возделывании [1]. Эффективное планирование агротехнических процессов и прогнозирование объемов сбора земляники садовой невозможно без регулярного наблюдения за состоянием растений и анализа их продуктивности [2]. Однако традиционные методы оценки урожайности, основанные на визуальном осмотре, требуют значительных трудозатрат и не всегда обеспечивают высокую точность. Эти методы предполагают регулярные обходы плантаций агрономами, которые визуально оценивают количество цветоносов, завязей и плодов, что является субъективным и время затратным процессом [3, 4, 5].

Морфологические особенности земляники садовой в отличие от клубники (*Fragaria vesca*), характеризуются низким габитусом, открытой структурой куста и визуально выделяющимися плодами [6, 7]. При этом цветки земляники садовой характеризуются более крупными размерами (диаметром 15-25 мм) и расположены на удлиненных цветоносах, возвышающихся на 5-15 см над листовой розеткой. Белые лепестки цветков создают выраженный цветовой контраст с зелёной листвой (значения NDVI 0,15-0,25 для цветков против 0,7-0,8 для листьев), а их пространственное распределение с интервалом 8-12 см способствует высокой точности распознавания при разрешении 0,5 см/пиксель с минимальным количеством ложноположительных срабатываний (<5%), сохраняя стабильность идентификации при углах съёмки до 30°, что позволяет применять методы дистанционного мониторинга на базе беспилотных летательных аппаратов (БЛА) [8, 9].

Применение беспилотных летательных аппаратов (БЛА) и алгоритмами компьютерного зрения, позволяют автоматизировать этот процесс, обеспечивая объективность и повторяемость результатов [10, 11]. Внедрение инновационных систем мониторинга, основанных на методах машинного обучения и обработки изображений, позволяет оптимизировать выращивание культуры, сократить потери урожая, повысить товарные характеристики ягод и обеспечить более рациональное использование ресурсов [12, 13, 14].

В современных зарубежных исследованиях

активно развиваются методы прогнозирования урожайности земляники садовой на основе дистанционного мониторинга и глубокого обучения [15]. В исследовании [9] предложили систему прогнозирования урожая земляники с использованием БЛА для получения детализированных ортофотопланов и сверточной нейронной сети Faster R-CNN для детекции цветков и плодов. Авторы достигли точности подсчета цветков 84,1% при среднем уровне взаимного перекрытия объектов распознавания 13,5%, показали возможность построения пространственных карт распределения цветков и плодов для мониторинга развития растений. В исследованиях [6] представлена гибридная легковесная сеть VM-YOLO, интегрирующая модель пространства состояний (VMamba). Предложенная модификация позволила достичь метрики mAP 71,4% при значительно сниженном количестве параметров (30 млн) по сравнению с базовыми моделями, что делает систему применимой для развертывания на мобильных платформах с ограниченными вычислительными ресурсами. Альтернативный подход к прогнозированию урожайности предложен в исследованиях [16], в которых вместо детекции цветков сосредоточились на распознавании цветоложа. Сочетание Faster R-CNN для детекции цветоложа с байесовским моделированием позволило создать статистически обоснованную модель прогноза урожайности.

В статье предлагается метод дистанционного мониторинга земляники с использованием БЛА DJI Mavic 3M и нейронной сети YOLO12. Сверточная нейронная сеть YOLO12, как усовершенствованная версия модели YOLO, показывает высокую скорость и точность обработки изображений в сложных условиях. Эта архитектура модели оптимизирована для задач распознавания объектов небольшого размера на сложном фоне [17, 18]. Разработанный метод позволит оптимизировать планирование урожая, сократить затраты на ручной труд и повысить эффективность производства за счет более точного прогнозирования сроков созревания и объемов урожая. Сочетание БЛА и современных методов глубокого обучения открывает перспективы для точного и автоматизированного прогнозирования урожайности земляники садовой [19]. Развитие этого направления предполагает интеграцию полученных данных с системами управления агропредприятиями,

позволит принимать более обоснованные управленческие решения на всех этапах производства ягодной продукции.

Цель исследования – разработка метода сбора и обработки данных для определения потенциальной урожайности земляники садовой на основе подсчёта цветков на изображениях с использованием БЛА, свёрточной нейронной сети YOLO12 и трансферного обучения (Transfer Learning).

Условия, материалы и методы. Разработан комплексный метод автоматического подсчёта цветков земляники садовой на высокодетализированных аэрофотоснимках, полученных с помощью беспилотных летательных аппаратов. Метод позволяет оценивать потенциальную урожайность на основе данных о количестве распознанных цветков. Процесс включает несколько этапов: создание ортофотоплана насаждений, разбиение ортофотоплана на отдельные фрагменты (изображения), детекцию цветков с использованием модели свёрточной нейронной сети на фрагментах и последующее объединение результатов для итогового подсчёта.

Сбор исходного набора данных (изображений), съёмка рядов садовых земляники садовой проводилась с использованием БЛА DJI Mavic 3 Multispectral (Mavic 3M), оснащённого RGB-камерой с матрицей CMOS (4/3", 20 Мп), фокусным расстоянием 24 мм и углом обзора 84°. Полеты выполнялись в ЗАО «Совхоз имени Ленина» в 2024 году, на высоте 30-60 метров в дневное время при ясной погоде. Маршрут полета квадрокоптера включал в себя движение над рядками земляники садовой сорта Зенга-Зенгана челночным способом. Освещение во время съёмки составляло от 60000 лк до 110000 лк. Участок

площадью 0,5 га характеризовался ровным рельефом. Агротехника возделывания соответствовала интенсивной технологии, однострочная схема посадки (ширина междурядий 0,9 м, расстояние между растениями в ряду 0,25 м) на мульчирующей пленке. Фенофаза растений на момент съёмки – массовое цветение.

Обработка исходных аэрофотоснимков для формирования высокоточного ортофотоплана выполнялась ПО Agisoft Metashape Pro версии 2.2.1. После импорта RGB-изображений высокого разрешения выполнено выравнивание снимков (Align Photos) с использованием алгоритма Structure-from-Motion (SfM), что позволяет восстановить позиции и ориентации камер с формированием разреженного облака точек. На следующем этапе было построено плотное облако точек (Build Dense Cloud) в режиме «Среднее качество» с применением «Мягкой фильтрации» для устранения выбросов. Затем на основе плотного облака была сгенерирована цифровая модель поверхности (DEM) (Build Mesh) с качеством «Среднее» и включенной опцией «Заполнение отверстий», что позволило построить полигональную модель (рис. 1). Для текстурирования модели была создана тайловая модель текстуры (Build Texture) с 7 уровнями детализации (0,570 мм/пиксель). Ортофотоплан (Build Orthomosaic) был экспортирован в режиме «Мозаика» на основе построенной поверхности, с разрешением 0,570 мм/пиксель, размером 8817×6301 пикселей, в цветовом пространстве RGB (3 канала, uint8), что обеспечило геометрически корректное, бесшовное и детализированное представление насаждений земляники, необходимое для последующего автоматизированного анализа.




Рис. 1 – Создание ортофотоплана в программе Agisoft Metashape Pro 2.2.1, цифровая модель поверхности

Fig. 1 – Orthophoto generation in Agisoft Metashape Pro 2.2.1, digital surface model

Для оптимизации вычислительных ресурсов исходный ортофотоплан разделяется на фрагменты размером 200×200 пикселей с помощью разработанного программного обеспечения на Python с использованием библиотек PyQt5, OpenCV и Pillow. Каждый фрагмент сохраняется с уникальным именем, содержащим информацию о его положении на исходном изображении,

что упрощает последующую обработку данных.

Подготовка датасета изображений осуществлялась в программе RectLabel путем ручной разметки объектов класса «Flower» (цветки земляники садовой) на 34 исходных RGB-изображениях (ортофотоплан) высокого разрешения (8192×5460 пикселей), полученных с БЛА (рис. 2).




Рис. 2 – Разметка цветков земляники садовой с использованием инструмента RectLabel

Fig. 2 – Annotation of garden strawberry flowers using the RectLabel tool

Каждый цветок выделен в ограничивающий прямоугольник (bounding box), координаты и метка класса автоматически сохранялись в соответствующий .txt файл в формате YOLO (нормализованные значения `class_id` `center_x` `center_y` `width` `height`). Для преодоления ограниченности исходной выборки и повышения устойчивости модели применялась комплексная аугментация: горизонтальное и вертикальное отражение (Flip) для адаптации к ориентации, изменение цветового оттенка ($\text{Hue} \pm 15\%$) для адаптации к вариациям освещенности, размытие Гаусса (Blur с коэффициентом 1%) для повышения устойчивости к легкой дефокусировке и мозаичное разбиение (Tile 5×5) исходных изображений на фрагменты (640×640 пикселя) для увеличения числа примеров изображений и обучения на различных частях участка. В результате аугментации исходный набор был расширен до 1700 изображений, а общее количество размеченных объектов класса «Flower» составило 18496, что сформировало репрезентативный датасет для обучения модели YOLO12.

Для распознавания цветков земляники садовой на полученных фрагментах использована сверточная нейронная сеть YOLO12 версия Extra Large (56,9 млн.

параметров, 194.9 GFLOPs). Обучение модели проводилось с применением техники трансферного обучения (transfer learning) для повышения точности распознавания. Гиперпараметры обучения: размер пакета данных (batch size) - 8, скорость обучения (learning rate) - 0,001, количество эпох обучения - 1500, ранняя остановка (early stopping) для предотвращения переобучения. Для фильтрации ложных срабатываний использовался алгоритм Non-Maximum Suppression (NMS), который удалял пересекающиеся ограничивающие рамки (bounding boxes) с низкой вероятностью распознавания, оставляя только наиболее точные результаты распознавания.

Для оценки качества работы модели использованы общепринятые метрики: точность (Precision), полнота (Recall), средняя точность (AP, Average Precision), F-мера (F-score), IoU (Intersection over Union) [20].

Обучение модели выполнялось на компьютере с процессором Intel Core i9-10900X (3.70 ГГц), двумя видеокартами NVIDIA GeForce RTX 2080 Ti (11 Гб каждая), оперативной памятью 128 Гб DDR4 и SSD-накопителем 1 Тб (PCI-E). В работе использовались библиотеки CUDA 12.2, PyTorch (работа с нейросетевыми моделями), OpenCV (обработка

изображений и визуализация), NumPy (численные операции с массивами) и другие инструменты для обработки данных и визуализации.

Результаты и обсуждение. В ходе обучения модели YOLO12 Extra Large на специализированном датасете достигнуты высокие и стабильные метрики детекции. На 1200 эпохе обучения модель показала следующие результаты: точность (Precision) 0,909, полнота (Recall) 0,803, средняя точность при

IoU=0,5 (mAP50) 0,885 и mAP50-95 0,783. Значения функций потерь стабилизировались на уровне box_loss = 0,35, cls_loss = 0,2 и dfl_loss = 0,76, что свидетельствует об отсутствии переобучения при использовании ранней остановки. Применение ранней остановки (patience = 100) прервало обучение на эпохе 1205 из-за отсутствия улучшений метрик, при этом пик производительности достигнут на 1105 эпохе (рис. 3).




Рис. 3 – График метрик обучения модели нейронной сети
Fig. 3 – Graph of the training metrics for the neural network model

Анализ модели на тестовой выборке (250 изображений, 1393 экземпляра) выявил следующие показатели: точность (Precision) 0,903, полнота (Recall) 0,812, F-мера 0,852 (гармоническое среднее точности и полноты), mAP50 0,888 и mAP50-95 0,783. Средняя скорость обработки кадров составила 14,81 мс/кадр для фрагментов 200×200

пикселей. Полученные метрики подтверждают применимость трансферного обучения для задач распознавания объектов небольшого размера в условиях сложного фона, обеспечивая точность автоматизированного подсчета цветков.

Примеры распознавания цветков земляники садовой на отдельных плитках и ортофотоплане представлены на рисунке 4.




Рис. 4 – Результаты распознавания цветков земляники садовой на ортофотоплане и отдельных плитках изображения

Fig. 4 – Results of strawberry flower recognition on an orthophotomap and individual image tiles

В результате проведенных исследований разработано специализированное программное обеспечение на Python с графическим интерфейсом (библиотека PyQt5), реализующее полный цикл обработки данных, от разбиения ортофотоплана до анализа пространственного распределения цветков и прогнозирования урожайности. Графический интерфейс программы обеспечивает управление процессом обработки через систему вкладок: вкладка

визуализация для отображения исходных изображений, плиток, результатов распознавания и сшитых ортофотопланов с поддержкой масштабирования, вкладка оценка урожайности для построения тепловых карт (heat map, цветовой градиент), анализа пространственного распределения, расчета прогноза урожая, вкладка база данных (библиотека SQLite3) для хранения и анализа исторических результатов обработки (рис. 5).




Рис. 5 – Интерфейс программы «ИИ-система картографирования урожайности земляники садовой»


Fig. 5 – Interface of the program «AI-based strawberry yield mapping system»

Программа включает в себя модуль по преобразованию изображений для автоматического разбиения ортофотоплана на фрагменты (плитки) заданного размера, управления параметрами разбиения (размер плитки, зазор между фрагментами). Модуль для распознавания цветков земляники садовой с помощью модели сверточной нейронной сети YOLO12, а также настройку порогов уверенности модели (confidence threshold) и IoU, визуализация результатов детекции с bounding boxes. Реализована поддержка пользовательских моделей (возможность загрузки файлов .pt через интерфейс) для обработки полученных данных, сшивки обработанных фрагментов в единое изображение с суммированием количества цветков и экспорта координат в формате GIS (Geographic Information System) (формула 1):

$$N_{\text{total}} = \sum_{i=1}^n n_i \quad (1)$$

где n_i - количество цветков на i -м фрагменте, шт, n - общее количество фрагментов, шт.

Для анализа пространственного распределения цветков на вкладке оценка урожайности проводится построение тепловой карты плотности цветков (рис. 6). Тепловая карта представляет собой визуализацию пространственного распределения плотности цветков земляники садовой на ортофотоплане [13]. Холодные цвета (синий) обозначают зоны с низкой плотностью цветков, теплые цвета (желтый, оранжевый, красный) показывают участки с высокой концентрацией цветков. Визуализация создается путем преобразования координат распознанных цветков в матрицу плотности с последующим наложением цветового градиента (от синего к красному) на исходное изображение, что позволяет агроному идентифицировать зоны неоднородной продуктивности.



Реализован расчет индекса Морана (библиотека esda) для оценки пространственной автокорреляции (формула 2):

$$I = \frac{n}{\sum_i \sum_j \omega_{ij}} \cdot \frac{\sum_i \sum_j \omega_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_i (x_i - \bar{x})^2} \quad (2)$$

Где n - число наблюдений, w_{ij} - элементы матрицы пространственных весов, x_i и x_j - значение в точках i и j , $\bar{x}$ - среднее значение.

При $I = 0,8$ ($p < 0,01$) сильная кластеризация, при $I = -0,3$ ($p < 0,05$) умеренное равномерное распределение.

Также проводится кластерный анализ методом K-means (библиотека scikit-learn) для выделения зон продуктивности (низкая/средняя/высокая) и визуализация диаграмм Вороного (библиотека SciPy) для оценки равномерности распределения. Индекс равномерности рассчитывается как коэффициент вариации площадей ячеек (формула 3):

$$U = \frac{\sigma A}{\mu A} \quad (3)$$

где σA - СКО площадей ячеек Вороного, m^2 , μA - средняя площадь, m^2 .

Прогнозирование урожайности проводится с учетом сортовых коэффициентов (Эльсанта – 0,85, Альба - 0,75, Хоней - 0,80 и др.). Расчет прогноза урожая проводится на основе количества распознанных цветков, среднего веса ягоды и площади участка (формула 4).

$$Y = \frac{N \cdot C_f \cdot V_f \cdot W_{avg}}{A} \quad (4)$$

где N - количество цветков, шт, C_f - базовый коэффициент преобразования, V_f - коэффициент сорта, W_{avg} - средний вес ягоды, г, A - площадь, m^2 .

Реализована поддержка параллельных вычислений через CUDA. Средняя скорость обработки кадров составляет ~67,5 FPS (плитка 200×200 px - 0,3125 кадр/сек) на видеокарте RTX 2080 Ti. В процессе работы программы ведется автоматическое ведение лога процессов.

На основе анализа пространственного распределения цветков земляники садовой с использованием разработанной ИИ-системы определены следующие закономерности. Выявленная кластеризация цветков земляники

садовой (индекс Морана = 0,987, $p < 0,01$) свидетельствует о значительной неоднородности продуктивности на участке (ортофотоплане) площадью 12,8 м². Высокий коэффициент вариации площадей ячеек Вороного ($U = 2,258$) подтверждает неравномерность распределения цветков, что коррелирует с особенностями почвенных условий или особенностями сорта. Прогнозная урожайность рассчитана с учетом сортового коэффициента, количества распознанных цветков (228 шт/м²) и среднего веса ягоды (35 г), составила 0,62 кг/м². Полученные данные позволяют определять зоны сниженной продуктивности (кластеры с индексом 0,279) для оптимизации выполнения технологических операций по уходу за насаждениями и подтверждают эффективность использования пространственного анализа с нейросетевым распознаванием.

Проведённое исследование показывает превосходство разработанного метода по метрикам распознавания цветков земляники садовой в сравнении с зарубежными аналогами. При разрешении съёмки 0,570 мм/пиксель архитектура YOLO12 Extra Large обеспечила значение метрики mAP50 на уровне 0,888, что на 5,8% превышает результат Faster R-CNN при сопоставимых условиях съёмки [1]. Более высокая точность подсчёта цветков (90,3% против 84,1%) достигнута при меньшем уровне взаимных перекрытий объектов (<5% против 13,5%), что обусловлено применением в исследованиях комплексной аугментации данных и оптимизированной предобработки ортофотоплана.

В отличие от легковесной гибридной сети VM-YOLO [2] обученная нами модель обеспечивает более высокую точность при сохранении вычислительной эффективности (~67,5 кадров/сек).

Метод, основанный на распознавании цветоложа [3] с последующим байесовским моделированием вероятности плодоношения, хотя и обоснован с биологической точки зрения, уступает по точности распознавания (метрика mAP 0,6587) и требует дополнительных этапов статистической обработки для прогнозирования урожайности. Он обеспечивает косвенную оценку потенциального урожая через вероятностное преобразование, а предлагаемый нами метод обеспечивает прямой подсчёт цветков с высокой точностью и встроенный механизм прогнозирования через сортовые коэффициенты, что сокращает время принятия

агротехнических решений.

Выводы. Разработанная программа «ИИ-система картографирования урожайности земляники садовой» решает актуальную задачу автоматизации мониторинга цветения земляники садовой с использованием БЛА и глубокого обучения, подсчета цветков земляники садовой на больших площадях в условиях высокой плотности насаждений для прогноза урожайности на ранних стадиях вегетации, снижая трудозатраты и повышая масштабируемость мониторинга. Применение современной архитектуры YOLO12 в сочетании с алгоритмами пространственного анализа обеспечивает высокую точность детекции (метрика средней точности mAP50 = 0,904 на 1105 эпохе обучения) и позволяет выявлять зоны неоднородности цветения. Метод обеспечил точность автоматизированного подсчета на уровне 90,3% (метрика Precision) и позволил выявить выраженную пространственную кластеризацию цветков (индекс Морана = 0,987) на исследованном участке.

Применение методов аугментации данных, таких как горизонтальное и вертикальное отражение (Flip), изменение цветового оттенка (Hue $\pm 15\%$), размытие Гаусса (Blur с коэффициентом 1%), мозаичное разбиение (Tile 5×5), позволило улучшить адаптивность модели к реальным условиям съёмки и повысить качество распознавания и классификации.

Модуль программы для прогнозирования урожайности с учетом сортовых особенностей создает основу для принятия агротехнических решений. На тестовых данных прогнозная урожайность составила 0,62 кг/м² при плотности цветения 228 шт/м². Предложенный метод существенно сокращает трудозатраты при оценке продуктивности и может быть адаптирован для других сельскохозяйственных культур с выраженными морфологическими признаками. Дальнейшее развитие метода предполагает уточнение моделей прогнозирования урожайности на основе биологических параметров сортов и динамики роста растений, что сделает систему еще более точной и адаптивной для задач цифрового мониторинга. Интеграция данных, полученных с БЛА и разработанной ИИ-системы, с системами управления сельскохозяйственной техникой позволит оптимизировать выполнение технологических операций (дифференцированное внесение удобрений, средств защиты растений) в режиме реального времени.

Литература

1. Динамика производства ягод земляники садовой по странам мира / В. Н. Ожерельев, М. В. Ожерельева, А. М. Гринь и др. // Вестник Брянской государственной сельскохозяйственной академии. 2019. №4(74). С. 60–66.
2. Марченко Л.А. Продуктивность земляники садовой и селекционные возможности ее повышения // Сибирский вестник сельскохозяйственной науки. 2021. №51(3). С. 65–74. doi: 10.26898/0370-8799-2021-3-7
3. Кутырёв А.И., Филиппов Р.А. Применение сверточной нейронной сети для мониторинга состояния земляники садовой // Аграрная наука Евро-Северо-Востока. 2023. Т.24. №4. С. 685–696. doi: 10.30766/2072-9081.2023.24.4.685-696
4. Разработка системы автоматизированного управления агротехнологиями в садоводстве / Д.О. Хорт, А.И. Кутырёв, И.Г. Смирнов и др. // Сельскохозяйственные машины и технологии. 2021. Т.15. №2. С. 61–68. doi: 10.22314/2073-7599-2021-15-2-61-68

5. 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. doi: 10.31676/0235-2591-2023-5-56-63
6. VM-YOLO: YOLO with VMamba for Strawberry Flowers Detection / Y. Wang, X. Lin, Z. Xiang, et al. // Plants. 2025. 14(3):468. doi: 10.3390/plants14030468
7. Strawberry Detection and Ripeness Classification Using YOLOv8+ Model and Image Processing Method / C. Wang, H. Wang, Q. Han, et al. // Agriculture 2024. 14(5):751. doi: 10.3390/agriculture14050751
8. Estimation of Strawberry Canopy Volume in Unmanned Aerial Vehicle RGB Imagery Using an Object Detection-Based Convolutional Neural Network / M-S. Gang, T. Sutthanonkul, W.S. Lee, et al. // Sensors 2024. 24(21):6920. doi: 10.3390/s24216920
9. Strawberry Yield Prediction Based on a Deep Neural Network Using High-Resolution Aerial Orthoimages / Y. Chen, W.S. Lee, H. Gan, et al. // Remote Sensing. 2019. 11(13):1584. doi: 10.3390/rs11131584
10. Improving Strawberry Yield Prediction by Integrating Ground-Based Canopy Images in Modeling Approaches / A. Abd-Elrahman, F. Wu, S. Agehara, et al. // ISPRS International Journal of Geo-Information. 2021. 10(4):239. doi: 10.3390/ijgi10040239
11. Deep learning for strawberry canopy delineation and biomass prediction from high-resolution images / C. Zheng, A. Abd-Elrahman, V.M. Whitaker, et al. // Plant Phenomics. 2022. 9850486. doi: 10.34133/2022/9850486
12. Yue Y., Xu S., Wu H.A. Strawberry Ripeness Detection Method Based on Improved YOLOv8 // Applied Sciences. 2025. 15(11):6324. doi: 10.3390/app15116324
13. YOLOv5-ASFF: A Multistage Strawberry Detection Algorithm Based on Improved YOLOv5 / Y. Li, J. Xue, M. Zhang, et al. // Agronomy. 2023. 13(7):1901. doi: 10.3390/agronomy13071901
14. Lightweight Improved YOLOv5s-CGHOSTNET for Detection of Strawberry Maturity Levels and Counting / N. Tamrakar, S. Karki, MY. Kang, et al. // AgriEngineering. 2024. 6(2):962-978. doi: 10.3390/agriengineering6020055
15. Research on the Strawberry Recognition Algorithm Based on Deep Learning / Y. Zhang, L. Zhang, H. Yu, et al. // Applied Sciences. 2023. 13(20):11298. doi: 10.3390/app132011298
16. Prediction of strawberry yield based on receptacle detection and Bayesian inference / S. Yoon, J.S. Jo, S.B. Kim, et al. // Heliyon. 2023. Vol. 9. No. 3. P. e14546. doi: 10.1016/j.heliyon.2023.e14546
17. Diwan T., Anirudh G., Tembhurne J.V. Object detection using YOLO: Challenges, architectural successors, datasets and applications // Multimed. Tools Appl. 2023. No. 82. P. 9243-9275. doi: 10.1007/s11042-022-13644-y
18. D-YOLO: A Lightweight Model for Strawberry Health Detection / E. Wu, R. Ma, D. Dong, et al. // Agriculture. 2025. 15(6):570. doi: 10.3390/agriculture15060570
19. A deep-level region-based visual representation architecture for detecting strawberry flowers in an outdoor field / P. Lin, W.S. Lee, Y.M. Chen, et al. // Precision Agric. 2020. 21. P. 387–402. doi: 10.1007/s11119-019-09673-7
20. 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: 10.3390/rs1313245

References

1. Ozherelev VN, Ozhereleva MV, Grin AM. [Dynamics of garden strawberry production in the countries of the world]. Vestnik Bryanskoy gosudarstvennoy selskokhozyaystvennoy akademii. 2019; 4(74). 60-66 p.
2. Marchenko L.A. [Productivity of garden strawberries and breeding potential for their improvement]. Sibirskiy vestnik selskokhozyaystvennoy nauki. 2021; 51(3). 65-74 p. doi: 10.26898/0370-8799-2021-3-7
3. Kutyrev AI, Filippov RA. [Application of convolutional neural network for monitoring the condition of garden strawberries]. Agrarnaya nauka Evro-Severo-Vostoka. 2023; Vol.24. 4. 685-696 p. doi: 10.30766/2072-9081.2023.24.4.685-696
4. Khort DO, Kutyrev AI, Smirnov IG. [Development of an automated management system for agricultural technologies in horticulture]. Selskokhozyaystvennye mashiny i tekhnologii. 2021; Vol.15. 2. 61-68 p. doi: 10.22314/2073-7599-2021-15-2-61-68
5. Kutyrev AI, Smirnov IG, Andriyanov NA. [Comparative analysis of neural network models for recognizing apple fruits on a tree crown]. Sadovodstvo i vinogradarstvo. 2023; 5. 56-63 p. doi: 10.31676/0235-2591-2023-5-56-63
6. Wang Y, Lin X, Xiang Z, VM-YOLO: YOLO with VMamba for strawberry flowers detection. Plants. 2025; 14(3). 468 p. doi: 10.3390/plants14030468
7. Wang C, Wang H, Han Q. strawberry detection and ripeness classification using YOLOv8+ model and image processing method. Agriculture. 2024; 14(5). 751 p. doi: 10.3390/agriculture14050751
8. Gang M-S, Sutthanonkul T, Lee WS. Estimation of strawberry canopy volume in unmanned aerial vehicle RGB imagery using an object detection-based convolutional neural network. Sensors. 2024; 24(21). 6920 p. doi: 10.3390/s24216920
9. Chen Y, Lee WS, Gan H. Strawberry yield prediction based on a deep neural network using high-resolution aerial orthoimages. Remote Sensing. 2019; 11(13). 1584 p. doi: 10.3390/rs11131584
10. Abd-Elrahman A, Wu F, Agehara S. Improving strawberry yield prediction by integrating ground-based canopy images in modeling approaches. ISPRS International Journal of Geo-Information. 2021; 10(4). 239 p. doi: 10.3390/ijgi10040239
11. Zheng C, Abd-Elrahman A, Whitaker VM. Deep learning for strawberry canopy delineation and biomass prediction from high-resolution images. Plant Phenomics. 2022; 9850486. doi: 10.34133/2022/9850486
12. Yue Y, Xu S, Wu HA. Strawberry ripeness detection method based on improved YOLOv8. Applied Sciences. 2025; 15(11). 6324 p. doi: 10.3390/app15116324
13. Li Y, Xue J, Zhang M. YOLOv5-ASFF: a multistage strawberry detection algorithm based on improved YOLOv5. Agronomy. 2023; 13(7). 1901 p. doi: 10.3390/agronomy13071901
14. Tamrakar N, Karki S, Kang MY. Lightweight improved YOLOv5s-CGHOSTNET for detection of strawberry maturity levels and counting. AgriEngineering. 2024; 6(2). 962-978 p. doi: 10.3390/agriengineering6020055

15. Zhang Y, Zhang L, Yu H. Research on the strawberry recognition algorithm based on deep learning. *Applied Sciences*. 2023; 13(20). 11298 p. doi: 10.3390/app132011298
16. Yoon S, Jo JS, Kim SB. Prediction of strawberry yield based on receptacle detection and Bayesian inference. *Heliyon*. 2023; Vol.9. No.3. e14546 p. doi: 10.1016/j.heliyon.2023.e14546
17. Diwan T, Anirudh G, Tembhurne JV. Object detection using YOLO: challenges, architectural successors, datasets and applications. *Multimed. Tools Appl.* 2023; No.82. 9243-9275 p. doi: 10.1007/s11042-022-13644-y
18. Wu E, Ma R, Dong D. D-YOLO: a lightweight model for strawberry health detection. *Agriculture*. 2025; 15(6). 570 p. doi: 10.3390/agriculture15060570
19. Lin P, Lee WS, Chen YM. A deep-level region-based visual representation architecture for detecting strawberry flowers in an outdoor field. *Precision Agric.* 2020; 21. 387-402 p. doi: 10.1007/s11119-019-09673-7
20. Maxwell AE, Warner TA, Guillen LA. Accuracy assessment in convolutional neural network-based deep learning remote sensing studies - Part 1: literature review. *Remote Sensing*. 2021; 13(13). 2450 p. doi: 10.3390/rs1313245

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Сведения об авторах:

Кутырёв Алексей Игоревич – кандидат технических наук, ведущий научный сотрудник отдела технологий и машин для садоводства, виноградарства и питомниководства Федерального научного агроинженерного центра ВИМ (109428, Российская Федерация, г. Москва, пр-д 1-й Институтский, д.5), e-mail: alexeykutyrev@gmail.com, ORCID 0000-0001-7643-775X

Филиппов Ростислав Александрович – кандидат сельскохозяйственных наук, ведущий научный сотрудник отдела технологий и машин для садоводства, виноградарства и питомниководства Федерального научного агроинженерного центра ВИМ (109428, Российская Федерация, г. Москва, пр-д 1-й Институтский, д.5), e-mail: rostislav-filippov@yandex.ru, ORCID 0000-0003-3586-3634

Вклад авторов:

А.И. Кутырёв - формулирование идеи, гипотезы, цели исследования, создание программного обеспечения, скриптов, алгоритмов, статистический или теоретический анализ данных, редактирование, доработка текста;

Р.А. Филиппов - разработка методов и процедур, проверка результатов, воспроизводимости, проведение экспериментов, сбор данных, управление данными: подготовка, аннотирование, хранение, написание первоначального текста статьи, создание графиков, схем и иллюстраций.

Все авторы ознакомились и одобрили окончательный вариант рукописи.

Поступила 25.07.2025; одобрена после рецензирования 22.02.2026; принята к публикации 01.04.2026.

Conflict of interest. The authors declare no conflict of interest.

Authors:

Kutyrev Aleksey Igorevich – Ph.D. of Technical Sciences, leading researcher of Department of Technologies and Machines for Horticulture, Viticulture and Nursery Federal Scientific Agroengineering Center VIM (1st Institutskiy Proyezd, Building 5, Moscow, 109428, Russian Federation), e-mail: alexeykutyrev@gmail.com, ORCID 0000-0001-7643-775X

Filippov Rostislav Aleksandrovich – Ph.D. Agricultural Sciences, leading researcher of Department of Technologies and Machines for Horticulture, Viticulture and Nursery Federal Scientific Agroengineering Center VIM (1st Institutskiy Proyezd, Building 5, Moscow, 109428, Russian Federation), e-mail: rostislav-filippov@yandex.ru, ORCID 0000-0003-3586-3634

Contribution of the authors:

A.I. Kutyrev — Conceptualization (idea formulation, hypothesis and research objectives), Software development, scripting, Algorithm design, Statistical and theoretical data analysis, Manuscript editing and revision;

R.A. Filippov — Methodology (development of methods and procedures), Validation (results verification and reproducibility), Experimentation, Data acquisition, Data management (preparation, annotation, storage), Initial draft writing, Creation of graphs, diagrams, and illustrations.

The authors have reviewed and approved the final manuscript.

Submitted 25.07.2025; revised 22.02.2026; accepted 01.04.2026.

