

4.3.1. Технологии, машины и оборудование для агропромышленного комплекса (технические науки)

doi:10.18286/1816-4501-2024-3-203-214

УДК 631.171.004.3:004.932

Трансферное обучение сверточной нейронной сети для распознавания и классификации плодов и цветков яблони на изображениях

А. И. Кутырёв, кандидат технических наук, ведущий научный сотрудник, заведующий лабораторией интеллектуальных цифровых систем мониторинга, диагностики и управления процессами в сельскохозяйственном производстве

ФГБНУ «Федеральный научный агроинженерный центр ВИМ»

109428, РФ, г. Москва, 1-й Институтский проезд, дом 5

✉ alexeykutyrev@gmail.com

Резюме. В статье представлены результаты исследований по разработке метода распознавания и классификации цветков и плодов яблони на кроне дерева на изображениях с помощью моделей сверточных нейронных сетей YOLOv8 с целью контроля качества выполнения технологической операции прореживания цветков яблони. Применены алгоритм машинного обучения и техника трансферного обучения (Transfer learning, TL). Используются параметры модели, полученные путем предварительного обучения на наборе данных COCO (Common Objects in Context), что позволяет ускорить процесс обучения сверточной нейронной сети. Собранный и расширенный в результате аугментации набор данных включал в себя 6000 изображений цветков и плодов яблони. Процесс обучения моделей включал в себя минимизацию совокупной функции потерь (Loss Function), а также оптимизацию параметров с использованием градиентного спуска и весовых коэффициентов. Для количественной оценки производительности разработанных моделей сверточных нейронных сетей использованы метрики точности (Precision), полноты (Recall), F1-меры (F-score) и средней точности обнаружения (mean Average Precision, mAP). Из полученных кривых Precision-Recall установлен порог классификации 0,47, который обеспечивает наилучшее соотношение между точностью и полнотой при распознавании плодов яблони и порог классификации 0,56 при распознавании цветков. Построена матрица ошибок (Confusion Matrix) для оценки производительности моделей машинного обучения. Анализ полученных результатов показал, что модель YOLOv8 распознала класс «apple» с метрикой mAP равной 0,84, класс «flowering» – 691, класс «rosebud» – 0,448. Трансферное обучение снижает риск переобучения моделей в условиях ограниченного объема данных, улучшает производительность и ускоряет процесс обучения на новых данных, обеспечивая устойчивость к изменениям в наборе данных при распознавании и классификации цветков и плодов яблони.

Ключевые слова: трансферное обучение, архитектура, сверточная нейронная сеть, распознавание, классификация, прогноз урожая, плоды и цветки яблони.

Для цитирования: Кутырёв А. И. Трансферное обучение сверточной нейронной сети для распознавания и классификации плодов и цветков яблони на изображениях // Вестник Ульяновской государственной сельскохозяйственной академии. 2024. №3 (67). С. 203-214. doi:10.18286/1816-4501-2024-3-203-214

Transfer learning of convolutional neural network for recognition and classification of apple tree fruits and blossoms in images

A. I. Kutyrev

Federal State Budgetary Scientific Institution «Federal Scientific Agroengineering Center VIM»

109428, Russia, Moscow, 109428, Russia, Moscow, 1st Institutsky dr., 5.

✉ alexeykutyrev@gmail.com

Abstract. The article presents results of the research on development of a method for recognizing and classifying of apple blossoms and fruits on the crown of a tree in images using YOLOv8 convolutional neural network models in order to control the quality of the technological operation of thinning of apple blossoms. The algorithm of machine learning and transfer learning technique (Transfer learning, TL) are applied. The model parameters obtained by pre-training on the COCO (Common Objects in Context) dataset are used, which allows to speed up the learning process of a convolutional neural network. The data collected and expanded as a result of augmentation included 6,000 images of apple blossoms and fruits. The training process of models included minimizing of the cumulative Loss Function, as well as improvement of parameters using gradient descent and weighting coefficients. To quantify the performance of the

developed models of convolutional neural networks, the metrics of accuracy (Precision), completeness (Recall), F1-measure (F-score) and average detection accuracy (mean Average Precision, mAP) were used. A classification threshold of 0.47 was established from the obtained Precision-Recall curves, which provides the best ratio between accuracy and completeness when recognizing apple fruits and a classification threshold of 0.56 when recognizing blossoms. An error Matrix (Confusion Matrix) was developed to evaluate the performance of machine learning models. The analysis of the results showed that the YOLOv8 model recognized the "apple" class with a mAP metric equal to 0.84, the "flowering" class – 0.691, the "rosebud" class – 0.448. Transfer learning reduces the risk of overfitting of models in the conditions of limited data volume, improves productivity and speeds up the learning process on new data, providing resistance to changes in the dataset when recognizing and classifying apple blossoms and fruits.

Keywords: transfer learning, architecture, convolutional neural network, recognition, classification, crop forecast, apple fruits and blossoms.

For citation: Kuttyrev A. I. Transfer learning of convolutional neural network for recognition and classification of apple tree fruits and blossoms in images // Vestnik of Ulyanovsk state agricultural academy. 2024;3(67): 203-214 doi:10.18286/1816-4501-2024-3-203-214

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

Введение

Многолетними исследованиями доказано, что прореживание цветков является важным этапом возделывания интенсивных яблоневых садов, который позволяет сбалансировать количество и размер плодов, а также обеспечивает достаточное количество цветочных бутонов на следующий год без снижения урожая в текущем году [1]. Научные исследования, проведенные в этой области, подтверждают, что своевременное и систематическое прореживание имеет большое значение для обеспечения ежегодной продуктивности яблони с прогнозируемым качеством плодов [2].

В интенсивном садоводстве существует множество методов расчета оптимального количества плодов и цветков, приходящихся на одно дерево. Количество плодов на дереве (в штуках) после его вступления в период плодоношения должно быть равно расстоянию в см между деревьями в ряду. При этом на один плод должно приходиться около 30 листьев. На 1 сантиметр окружности побега должно приходиться не более 4...6 плодов по истечению четырех недель после цветения, при этом расстояние между плодами на ветке должно составлять около 15...20 см (5...6 кг плодов на 1 см поперечного сечения ствола дерева). Оптимальная норма нагрузки урожаем (количество плодов на одно дерево, шт.) в зависимости от возраста насаждений в садах интенсивного типа: в первый год – 5...6 плодов, второй год – 20...30 плодов, третий год – 40...50 плодов, четвертый год – 60...80 плодов, пятый год 80...100 и более плодов. При этом количество плодов составляет от 4 % до 8 % от числа цветков на дереве [3].

Существующие методы проведения операции прореживания, включая ручные, химические и механические, показывают высокую эффективность, тем не менее, основной трудностью при их применении остается значительная степень непредсказуемости конечного результата [4, 5, 6]. В связи с этим для контроля и оценки качества прореживания цветков яблони и прогнозирования урожая путем

подсчета количества цветков и плодов на кроне дерева необходим мониторинг проведения данной операции.

Цель исследования – разработка метода распознавания и классификации цветков и плодов яблони на кроне дерева на основе алгоритмов машинного обучения с применением техники трансферного обучения для контроля качества проведения технологической операции прореживания цветков яблони.

Материалы и методы

Большинство разработанных систем компьютерного зрения для распознавания плодов и цветков яблони сосредоточены на обнаружении и сегментации кластеров [7]. До широкого применения методов глубокого обучения сегментацию кластеров осуществляли с помощью автоматического выделения цветовых и текстурных характеристик на RGB-изображениях с использованием таких техник, как пороговая обработка интенсивности и морфологическая обработка изображений [8, 9]. Алгоритмы сегментации кластеров из-за изменчивости условий освещения, биологической изменчивости крон, взаимного перекрытия объектов (ветвей, листьев, цветков, завязей и плодов) и изменения формы, размера, цвета и других параметров биологических объектов обладают невысокой производительностью [10].

Использование методов машинного обучения, сверточных нейронных сетей (Convolutional Neural Networks, CNN) для обнаружения и сегментации цветков и плодов яблони позволило значительно повысить производительность классификации и распознавания этих биологических объектов [11, 12, 13]. Одним из главных преимуществ данных архитектур является более высокая производительность [14, 15]. Использование архитектуры сверточной нейронной сети YOLO (You Only Look Once) для обнаружения объектов на изображениях и видео обеспечивает высокую скорость и точность при

выполнении задачи распознавания образов в реальном времени (рис. 1).

Алгоритм YOLO разбивает изображение на сетку ячеек, чтобы предсказать объекты в каждой ячейке. Этот метод позволяет обнаруживать несколько объектов и определять координаты, классы и уверенности в принадлежности объекту для каждого обнаруженного объекта [16, 17].

Для создания набора данных для обучения нейронной сети использована цифровая камера Sony Alpha ILCE-7M3 с объективом Sony FE 24-240 mm. Съемку проводили со следующими параметрами: уровень открытия диафрагмы объектива - f/7.1, фокусное расстояние – 24 мм, разрешение изображений - 4000x2672 пикселей. Набор данных, состоящий из 3000 изображений цветков и плодов яблони, был собран в научно-производственном отделе ФГБНУ ФНЦ Садоводства (Московская область, р.п. Михнево). Изображения были разделены на две категории: цветы в стадии розового бутона и в стадии активного цветения, а также плоды яблони по 1500 изображений в каждой категории.

Подготовка набора данных для обучения модели сверточной нейронной сети включала процесс разметки изображений с использованием веб-

сервиса RoboFlow. В этом процессе были определены классы для классификации и распознавания объектов, включая «apple» (плоды яблони), «rosebud» (цветы в стадии розового бутона) и «flowering» (цветы в стадии цветения) (рис. 2).

Разметка объектов проведена с использованием прямоугольников – это процесс обведения интересующих объектов на изображении прямоугольниками с указанием соответствующего класса. Файл разметки в формате JSON использован для хранения информации о классах, с сохранением атрибутов, таких как "class" (класс объекта), "x_center" и "y_center" (координаты центра), а также "width" и "height" (ширина и высота объекта).

Для расширения набора данных и улучшения производительности модели применен метод аугментации. Использованы инструменты Flip, Rotation $\pm 15^\circ$, Hue $\pm 25^\circ$, Noise 5 %, Blur 2,5 px, Brightness $\pm 25\%$. Flip и Rotation помогают справиться с проблемой неинвариантности относительно поворотов и отражений. Изменение оттенка и яркости (Hue, Brightness) помогает модели лучше обобщать цветовую информацию. Добавление шума и размытия (Noise, Blur) помогает модели стать более устойчивой к артефактам в данных (рис. 3).




Рис. 1. Архитектура модели нейронной сети YOLOv8




Рис. 2. Процесс разметки изображений плодов и цветков яблони для создания обучающей, валидационной и тестовой выборки



Рис. 3. Используемые методы аугментации изображений цветков и плодов яблони для расширения набора данных

В результате набор данных (dataset) был расширен до 6000 изображений: цветы в стадии розового бутона - 1500 изображений, цветы в стадии активного цветения - 1500 изображений, плоды яблони - 3000 изображений. Для оценки производительности модели набор данных был разделен на три подвыборки: обучающую (70 % или 4200

изображений), тестовую (30 % или 1200 изображений) и валидационную (10 % или 600 изображений). Этот метод обеспечивает сбалансированное разделение данных, позволяя эффективно оценивать способность модели к обобщению.

Проведена визуализация проведенной разметки с использованием тепловой карты (Heatmap),

представляющей собой двумерный массив, где каждый пиксель изображения отражает интенсивность с использованием цветовой шкалы. Выделены

области, признанные моделью наиболее вероятными для наличия заданных классов – цветков и плодов яблони (рис. 4).




Рис. 4. Тепловые карты цветков и плодов яблони

Карта интенсивности является инструментом, который обеспечивает анализ и интерпретацию входных данных, позволяя выявить области изображения, которые считаются наиболее информативными и значимыми при обучении модели нейронной сети.

Для обучения сверточной нейронной сети использован метод трансферного обучения (Transfer learning, TL), при котором заранее обученная модель используется для решения новой задачи. Этот подход позволяет использовать знания, полученные моделью на другой задаче или наборе данных, для улучшения обучения на целевой задаче. Создан файл конфигурации, содержащий информацию о путях к обучающим и тестовым изображениям, а также пути к файлам с разметкой. В файле конфигурации модели определены ключевые параметры обучения, включая количество эпох (epoch), размер

пакета данных (batch size) и скорость обучения (learning rate). Оптимальные значения указанных параметров были определены эмпирически в результате тестирования и настройки в ходе серии экспериментов. Этот метод включает в себя итеративный процесс, в ходе которого проведены множественные обучающие запуски с изменением значений каждого параметра, что позволяет выявить наилучшие конфигурации для обеспечения эффективного обучения модели.

Для обучения модели использован набор данных COCO (Common Objects in Context), что позволило ускорить процесс обучения нейронной сети на своих собственных данных. Набор данных COCO включает обширный набор изображений с разметкой, охватывающий разнообразные объекты в различных контекстах (рис. 5).



Рис. 5. Набор данных COCO 2023 в программной среде FityOne

Процесс обучения включал в себя минимизацию совокупной функции потерь (Loss Function), а также оптимизацию параметров с использованием градиентного спуска и весовых коэффициентов. Для обновления весовых коэффициентов в процессе обучения моделей с использованием градиентного спуска использована формула 1:

$$\omega_{\text{нов.}} = \omega_{\text{стар.}} - \alpha \Delta L(\omega_{\text{стар.}})_i \quad (1)$$

где $\omega_{\text{нов.}}$ – новый весовой коэффициент; $\omega_{\text{стар.}}$ – старый весовой коэффициент; α – скорость обучения, определяющая размер шага в направлении градиента; $\Delta L(\omega_{\text{стар.}})_i$ – вектор, который указывает направление наискорейшего возрастания функции потерь ΔL относительно весового коэффициента $\omega_{\text{стар.}}$.

Этот процесс повторяется в течение нескольких итераций (эпох) до достижения сходимости или заданного критерия остановки обучения модели. В результате этого процесса обучаемая модель сверточной нейронной сети постепенно настраивается на обучающих данных, улучшая свою способность к обнаружению объектов. Для оценки точности предсказания координат ограничивающего прямоугольника (box) для объектов на изображении в алгоритме обучения модели YOLOv8 использована функция потерь Box Loss:

$$\text{Функция потерь (Box Loss)} = \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{\text{obj}} [(x_i - \hat{x}_i)^2 + (y_j - \hat{y}_j)^2] \quad (2)$$

где S – размер сетки; B – количество ограничивающих рамок (anchor box); λ_{coord} – весовой коэффициент для определения ошибки в распознавании координат (Loss); 1_{ij}^{obj} – индикатор, показывающий, принадлежит ли объект ограничивающей рамке i ; j ; x_i, y_j – координаты центра распознанной ограничивающей рамки; $\hat{x}_i, \hat{y}_j$ – соответствующие координаты истинной ограничивающей рамки.

Формула Box Loss включает в себя весовые коэффициенты, чтобы балансировать важность различных ошибок в обучении модели. Метрику Detection Rate (скорость обнаружения) моделью объектов определяют по формуле 3:

$$\text{Скорость распознавания (Detection Rate)} = \frac{N_{\text{obj}}}{N_{\text{max}} \cdot t_{\text{сек}}} \cdot 100 \% \quad (3)$$

где N_{obj} – количество обнаруженных объектов, шт.; N_{max} – общее количество объектов на изображении, шт.; $t_{\text{сек}}$ – время распознавания объектов, с.

После завершения обучения моделей была проведена оценка их производительности с использованием тестовой выборки, которая не использовалась в процессе обучения. Для количественной оценки производительности разработанных моделей при распознавании и классификации объектов (цветков и плодов яблони) использованы известные

метрики точности (Precision), полноты (Recall), F1-мера (F-score) и средней точности обнаружения (mean Average Precision, mAP), найденные по формулам 4 – 7.

$$\text{Точность (Precision)} = \frac{1}{C} \sum_{i=1}^C \frac{TP_i}{TP_i + FP_i}; \quad (4)$$

$$\text{Полнота (Recall)} = \frac{1}{C} \sum_{i=1}^C \frac{TP_i}{TP_i + FN_i}; \quad (5)$$

$$\text{F1 – мера (F1 – score)} = \frac{1}{C} \sum_{i=1}^C \frac{2 \cdot \text{Precision}_i \cdot \text{Recall}_i}{\text{Precision}_i + \text{Recall}_i}; \quad (6)$$

$$\text{Средняя точность (mAP)} = \frac{1}{C} \sum_{i=1}^C AP_i \quad (7)$$

где C – общее количество классов; TP_i – количество верно классифицированных положительных примеров для класса i ; FP_i – количество ложноположительных примеров для класса i ; FN_i – количество ложноотрицательных примеров для класса i ; AP_i – площадь под кривой точности-полноты для класса i .

В этих формулах TP_i , FP_i и FN_i относятся к истинно положительным, ложноположительным и ложноотрицательным примерам для класса i соответственно.

Площадь под кривой точности-полноты AP_i для класса i была вычислена с использованием кривой точности-полноты (Precision-Recall curve). Данная кривая построена для различных порогов классификации, определяющих вероятность, выше которой объект считается принадлежащим к заданному классу.

Показатель доверительности (Confidence) определен по формуле 8 как максимальная вероятность принадлежности объекта к одному из классов: Доверительность (Confidence) = $\max_i P(c_i | x)$, (8)

где $P(c_i | x)$ – предсказанная моделью вероятность того, что объект x принадлежит классу c_i ; $\max_i$ – операция выбора максимального значения среди всех вероятностей принадлежности объектов к различным классам.

Для проведения исследований использовали вычислительную систему, оснащенную процессором Intel Core i9 с двадцатью виртуальными потоками. Обучение модели осуществлялось при использовании двух видеокарт NVIDIA и GeForce RTX 2080 Ti. Для хранения данных применяли твердотельный накопитель SSD Intel PCI-E объемом 1 Тб. Объем оперативной памяти системы составлял 32 Гб с использованием модулей Kingston DDR4 DIMM.

Результаты

Полученная зависимость функции потерь для определения ограничивающих рамок от числа эпох (Box Loss-Epoch) в процессе обучения модели позволила определить оптимальное количество эпох, при котором достигается наилучшее качество определения координат ограничивающих рамок. Оптимальное качество определения координат

ограничивающих рамок достигнуто на 124-й эпохе обучения (рис. 6). Анализ кривых Precision-Epoch, Recall-Epoch, построенных для оценки изменения точности и полноты модели в зависимости от эпохи обучения, а также кривой mAP-Epoch, построенной для оценки изменения средней точности модели в зависимости от количества эпох в процессе обучения, позволил определить оптимальное количество эпох для нахождения баланса между точностью и

полнотой. Выбрано количество эпох, равное 130, для достижения наилучшей производительности модели и максимальной точности распознавания классов «apple», «rosebud» и «flowering». Общее время обучения модели при использовании CPU на плодах яблони составило 8 часов 35 минут 25 секунд, а на цветках яблони – 9 часов 15 минут 15 секунд.




Рис. 6. Зависимости Box loss, Precision, Recall и mAP от эпохи обучения: а – плоды яблони, б – цветы яблони



Рис. 7. Примеры распознавания и классификации: а - плоды яблони, б – цветки яблони

На рисунке 7 представлены примеры распознавания классов «apple», «rosebud» и «flowering» на изображениях тестового набора данных.

Для оценки изменения точности и полноты при изменении порога принятия решения в задаче

классификации были построены кривые F1-score-Confidence, Precision-Confidence, Precision-Recall и Recall-Confidence (рис. 8, 9).




Рис. 8. К оценке качества работы разработанной модели сверточной нейронной сети YOLOv8 для распознавания и классификации плодов яблони: а – зависимость F1-score от Confidence, б – зависимость Precision от Confidence, в – зависимость Precision от Recall, г – зависимость Recall от Confidence




Рис. 9. К оценке качества работы разработанной модели сверточной нейронной сети YOLOv8 для распознавания и классификации цветков яблони: а – зависимость F1-score от Confidence, б – зависимость Precision от Confidence, в – зависимость Precision от Recall, г – зависимость Recall от Confidence

Анализ графика Precision-Recall позволил установить порог классификации 0,47, который обеспечивает наилучшее соотношение между точностью и полнотой распознавания плодов яблони и порог классификации 0,56 при распознавании цветков.

Полученные кривые (Precision-Confidence и Recall-Confidence) отображают зависимость точности и полноты предсказаний модели от уровня доверительности, используемого при принятии решения о наличии объекта на изображении. Из анализа кривых был определен оптимальный уровень доверительности для моделей: 0,49 для распознавания плодов яблони и 0,52 для цветков яблони. Этот показатель обеспечивает оптимальную точность и полноту предсказаний классов при минимальном количестве ложных срабатываний модели. F1-Confidence

график позволил оценить влияние уровня уверенности модели на объединенные метрики точности и полноты, а также установить оптимальный порог для классификации: 0,51 для плодов яблони и 0,48 для цветков яблони. Этот график также показывает, как модель реагирует на различные уровни шума или наличие выбросов в данных.

Для оценки производительности модели машинного обучения построена матрица ошибок (Confusion Matrix). В матрице содержатся основные категории, которые отражают, как модель классифицировала объекты. Матрица позволила провести оценку ошибок модели и настроить параметры модели для улучшения ее производительности при распознавании классов «apple», «flowering» и «rosebud» (рис. 10, 11).




Рис. 1. Матрица ошибок: а - плодов яблони, б - цветков яблони

Таблица 2. Результаты расчета метрик бинарной и мультиклассовой классификации обученных моделей YOLOv8

Класс	Точность	Полнота	Средняя точность mAP@50
Flowering	0,697	0,642	0,691
Rosebud	0,467	0,506	0,448
Мультикласс (flowering + rosebud)	0,582	0,574	0,569
Apple	0,867	0,748	0,84
Все классы	0,65325	0,6175	0,637

В таблице 2 представлены коэффициенты трех основных метрик для каждого индивидуального класса и для общего набора данных после обучения моделей YOLOv8.

Модель YOLOv8 распознала класс «apple» с метрикой mAP = 0,84, класс «flowering» - 0,691, а класс «rosebud» - 0,448. Своевременный мониторинг плодов и цветков яблони на промышленной плантации с применением для обработки полученных данных свёрточной нейронной сети YOLOv8 позволит с высокой средней точностью (mAP = 0,64)

распознавать и классифицировать плоды и цветки яблони в режиме реального времени.

Обсуждение

Применение методов компьютерного зрения в промышленном садоводстве затруднено различными факторами окружающей среды, а также сортовыми особенностями садовых культур, такими как разные условия освещения, визуальные различия между биологическими объектами (цвет, размер и т.д.), а также наличие препятствий в виде листвы и ветвей. Эти факторы требуют дифференцированного подхода и разработки адаптивных методов для

эффективного анализа визуальных данных в промышленных садах [18, 19]. Результаты проведенного исследования по использованию модели YOLOv8 для распознавания и классификации на изображениях плодов и цветков яблони показывают высокую эффективность и перспективность данного подхода для применения в режиме реального времени в составе мобильных энергетических средств в виде системы поддержки принятия решений для мониторинга урожайности, оценки количества плодов, планирования прореживания цветков и формирования завязей [20, 21, 22].

Процесс дообучения моделей нейронных сетей при их работе позволит существенно улучшить производительность распознавания и классификации плодов и цветков яблони в конкретных условиях эксплуатации. Этот процесс позволит адаптировать модель к особенностям окружающей среды и изменениям в данных, что дополнительно повысит точность и производительность моделей в производственных условиях.

Для подсчета количества биологических объектов относительно каждого ряда насаждений или дерева и исключения дублирования их учета необходима разработка способа трекинга (процесса отслеживания) объектов или нескольких объектов на видео/наборе кадров путем присвоения каждому распознанному объекту уникального идентификатора (ID). Трекинг позволит определить перемещение и изменения положения биологических объектов на изображениях во времени. Метод трекинга обеспечит возможность сбора информации о состоянии насаждений в режиме реального времени, что позволит оперативно реагировать на изменения и принимать оптимальные управленческие решения.

Литература

1. Schupp J.R., Kon T.M. Mechanical Blossom Thinning of 'GoldRush'/M.9 Apple Trees with Two String Types and Two Timings // Journal of the American Pomological Society. 2014. No. 68 (1). P. 24-32.
2. Effects of lime sulfur and fish oil on pollen tube growth, leaf photosynthesis and fruit set in apple / S. McCartney, J. Palmer, S. Davies // HortScience. No. 41 (2). P. 357-360.
3. Dennis F. J. The history of fruit thinning // Plant growth regulation. 2000. No. 31. P. 1-16.
4. Reighard G. L., Henderson W. G. Mechanical blossom thinning in south carolina peach orchards // In I International Symposium on Mechanical Harvesting and Handling Systems of Fruits and Nuts. 2012. Vol. 965. P. 117-121.
5. Miller S.S., Tworokski T. Blossom thinning in apple and peach with an essential oil // HortScience. 2010. No. 45 (8). P. 1218-1225.
6. Evaluation of apple flowering intensity using color image processing for tree specific chemical thinning / O. Krikeb, V. Alchanatis, O. Crane, et al. // Advances in Animal Biosciences. 2017. No. 8 (2). P. 466-470.
7. Dias P. A., Tabb A., Medeiros H. Multispecies fruit flower detection using a re ned semantic segmentation network // Ieee robotics and automation letters. 2008. No. 3(4). P. 3003-3010.
8. Flowering estimation in apple orchards by imageanalysis / M. Hocesvar, B. Sirok, T. Godesa et al. // Precision Agriculture. 2014. No. 15 (4). P. 466-478.
9. Dias P. A., Tabb A., Medeiros H. Apple flower detection using deep convolutional networks // Computers in Industry. 2018. No. 99. P. 17-28.
10. Yield prediction in apple orchards based on image processing / A. Aggelopoulou, D. Bochtis, S. Fountas, et al. // Precision Agriculture. 2011. No. 12(3). P. 448-456.
11. Making Sense of Light: The Use of Optical Spectroscopy Techniques in Plant Sciences and Agriculture / A.M. Cavaco, A.B. Utikin, J. Marques da Silva, et al. // Appl. Sci. 2022. 12. 997.

Такой подход обеспечит не только точный учет и прогноз, но и динамичный мониторинг состояния насаждений, способствуя повышению эффективности производственного процесса.

Заключение

Определены оптимальные параметры настройки сверточной нейронной сети YOLOv8 для распознавания и классификации плодов яблони и ее цветков в стадиях розового бутона и цветения. Выбраны пороги уверенности 0,51 для обнаружения плодов яблони (со средней точностью 0,84) и 0,48 для обнаружения цветков яблони (со средней точностью 0,569), которые обеспечивают сбалансированное соотношение с количеством обнаруженных объектов.

Установлена конфигурация алгоритма машинного обучения модели: использовано 130 эпох (epochs) обучения, количество обучающих примеров за одну итерацию обучения (batch size) составило 16, скорость обучения установлена на уровне 0,01 LR (learning rate), размер входного изображения – 640 px.

Применение методов искусственного увеличения обучающей выборки существенно улучшает эффективность обучения нейронной сети, способствует адаптации моделей к реальным условиям и приводят к повышению точности обнаружения признаков классов на 12 %, по сравнению с обучением на исходном объеме данных.

Трансферное обучение улучшает производительность и ускоряет процесс обучения на новых данных, обеспечивая устойчивость к изменениям в наборе данных при распознавании и классификации цветков и плодов яблони.

12. Automatic blossom detection in apple trees using deep learning / U. Bhattarai, S. Bhusal, Y. Majeed, et al. // IFAC-PapersOnLine. 2020. No. 53(2). P. 15810-15815.
13. Detection and counting of flowers on apple trees for better chemical thinning decisions / G. Farjon, O. Krikeb, A.B. Hillel, et al. // Precision Agriculture. 2019. No. 21(3). P. 1-19.
14. Управление движением сельскохозяйственной автономной роботизированной платформы / Д. О. Хорт, А. И. Кутырёв, И. Г. Смирнов и др. // Сельскохозяйственные машины и технологии. 2023. №17(1). С. 25-34.
15. Разработка системы автоматизированного управления агротехнологиями в садоводстве / Д. О. Хорт, А. И. Кутырёв, И. Г. Смирнов и др. // Сельскохозяйственные машины и технологии. 2021. №15(2). С. 61-68.
16. Кутырёв А. И. Распознавание и классификация болезней листьев яблони на основе анализа их изображений моделями сверточных нейронных сетей (CNN) // Вестник Ульяновской государственной сельскохозяйственной академии. 2023. № 3 (63). С. 215-223.
17. Wu D., Lv S., Jiang M., Song H. Using channel pruning-based YOLO v4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments // Computers and Electronics in Agriculture. 2020. No. 178. P. 105742.
18. Real-Time Detection and Location of Potted Flowers Based on a ZED Camera and a YOLO V4-Tiny Deep Learning Algorithm / J. Wang, Z. Gao, Y. Zhang, J. Zhou, J. Wu, P. Li // Horticulturae. 2022. Vol. 8. No. 1. P. 21. doi: doi:10.3390/horticulturae8010021.
19. Studies in precision crop load management of apple / T.L. Robinson, L. Gonzalez, L. Cheng, Y. Ziang, G. Peck, B. Arnoldussen, M. Gomez, M. Guerra, M. Miranda Sazo, C. Kahlke // Acta Hortic. 2023. P. 219-226. DOI: doi:10.17660/ActaHortic.2023.1366.25.
20. Повышение эффективности системы управления растениеводством на основе цифровых технологий / Г.С. Клычова, А. Р. Закирова, А. Р. Валиев и др. // Вестник Казанского государственного аграрного университета. 2021. Т. 16. № 3 (63). С. 121-127.
21. Анализ и тенденции развития сельского хозяйства в условиях цифровизации / А. К. Субаева, М. Н. Калимуллин, М. М. Низамутдинов и др. // Вестник Казанского государственного аграрного университета. 2022. Т. 17. № 1(65). С. 135-141.
22. Использование цифровых технологий в растениеводстве для хранения и анализа данных истории полей / Н. В. Степных, Е. В. Нестерова, А. М. Заргарян, С. А. Копылова // Достижения науки и техники АПК. 2022. Т. 36, № 3. С. 97-102. doi: 10.53859/02352451_2022_36_3_97

References

1. Schupp J.R., Kon T.M. Mechanical Blossom Thinning of 'GoldRush'/M.9 Apple Trees with Two String Types and Two Timings // Journal of the American Pomological Society. 2014. No. 68(1). P. 24-32.
- 2.. Effects of lime sulfur and fish oil on pollen tube growth, leaf photosynthesis and fruit set in apple / S. McCartney, J. Palmer, S. Davies // HortScience. No. 41(2). P. 357-360.
3. Dennis F. J. The history of fruit thinning // Plant growth regulation. 2000. No. 31. P. 1-16.
4. Reighard G. L., Henderson W. G. Mechanical blossom thinning in south Carolina peach orchards // In I International Symposium on Mechanical Harvesting and Handling Systems of Fruits and Nuts. 2012. Vol. 965. P. 117-121.
5. Miller S.S., Tworowski T. Blossom thinning in apple and peach with an essential oil // HortScience. 2010. No. 45 (8). P. 1218-1225.
6. Evaluation of apple flowering intensity using color image processing for tree specific chemical thinning / O. Krikeb, V. Alchanatis, O. Crane, et al. // Advances in Animal Biosciences. 2017. No. 8 (2). P. 466-470.
7. Dias P. A., Tabb A., Medeiros H. Multispecies fruit flower detection using a re ned semantic segmentation network // IEEE robotics and automation letters. 2008. No. 3(4). P. 3003-3010.
8. Flowering estimation in apple orchards by imageanalysis / M. Hocesvar, B. Sirok, T. Godesa et al. // Precision Agriculture. 2014. No. 15(4). P. 466-478.
9. Dias P. A., Tabb A., Medeiros H. Apple flower detection using deep convolutional networks // Computers in Industry. 2018. No. 99. P. 17-28.
10. Yield prediction in apple orchards based on image processing / A. Aggelopoulou, D. Bochtis, S. Fountas, et al. // Precision Agriculture. 2011. No. 12(3). P. 448-456.
11. Making Sense of Light: The Use of Optical Spectroscopy Techniques in Plant Sciences and Agriculture / A.M. Cavaco, A.B. Utkin, J. Marques da Silva, et al. // Appl. Sci. 2022. 12. 997. 12. Automatic blossom detection in apple trees using deep learning / U. Bhattarai, S. Bhusal, Y. Majeed, et al. // IFAC-PapersOnLine. 2020. No. 53(2). P. 15810-15815.
13. Detection and counting of flowers on apple trees for better chemical thinning decisions / G. Farjon, O. Krikeb, A.B. Hillel, et al. // Precision Agriculture. 2019. No. 21(3). P. 1-19.
14. Motion control of an agricultural autonomous robotic platform / D. O. Khort, A. I. Kutyrev, I. G. Smirnov et al. // Agricultural machinery and technology. 2023. No. 17 (1). P. 25-34.
15. Development of an automated control system for agricultural technologies in horticulture / D. O. Khort, A. I. Kutyrev, I. G. Smirnov, et al. // Agricultural machinery and technologies. 2021. No. 15 (2). P. 61-68.

16. Kuttyrev A. I. Recognition and classification of apple leaf diseases based on the analysis of their images by convolutional neural network (CNN) models // Vestnik of Ulyanovsk State Agricultural Academy. 2023. No. 3 (63). P. 215-223.
17. Wu D., Lv S., Jiang M., Song H. Using channel pruning-based YOLO v4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments // Computers and Electronics in Agriculture. 2020. No. 178. P. 105742.
18. Real-Time Detection and Location of Potted Flowers Based on a ZED Camera and a YOLO V4-Tiny Deep Learning Algorithm / J. Wang, Z. Gao, Y. Zhang, J. Zhou, J. Wu, P. Li // Horticulturae. 2022. Vol. 8.No. 1. P. 21. doi: doi:10.3390/horticulturae8010021.
19. Studies in precision crop load management of apple / T.L. Robinson, L. Gonzalez, L. Cheng, Y. Ziang, G. Peck, B. Arnoldussen, M. Gomez, M. Guerra, M. Miranda Sazo, C. Kahlke // Acta Hortic. 2023. P. 219-226. doi: doi:10.17660/Acta-Hortic.2023.1366.25.
20. Improvement of the efficiency of crop management systems based on digital technologies / G.S. Klychova, A. R. Zakirova, A. R. Valiev, et al. // Vestnik of Kazan State agrarian university. 2021. Vol. 16. No. 3 (63). P. 121-127.
21. Analysis and trends of agricultural development in the context of digitalization / A. K. Subaeva, M. N. Kalimullin, M. M. Nizamutdinov, et al. // Vestnik of Kazan State Agrarian University. 2022. Vol. 17. No. 1(65). P. 135-141.
22. Stepnykh N.V., Nesterova E.V., Zargaryan A.M., et al. Using digital technologies in crop production to store and analyse field history data. Dostizheniya nauki i tekhniki APK. 2022;36(3):97-102. doi: 10.53859/02352451_2022_36_3_97.