

EDN IUDJFX

DOI 10.5281/zenodo.8271986

УДК 631.171.004.3:004.932

Кутырёв А. И., Филиппов Р. А.

РАСПОЗНАВАНИЕ ГЕНЕРАТИВНЫХ ЧАСТЕЙ ЗЕМЛЯНИКИ САДОВОЙ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ (CNN)

ФГБНУ «Федеральный научный агроинженерный центр ВИМ»

Реферат. В статье предложен метод сбора, анализа и классификации данных для распознавания генеративных частей земляники садовой с применением сверточной нейронной сети. Трансферное обучение модели сверточной нейронной сети YOLOv7 проведено на наборе данных с выделением четырех классов развития генеративных образований. В результате проведенных исследований (2022 г.) сформирован набор изображений цветков, завязей, зрелых и незрелых ягод. Для обеспечения баланса классов в используемом наборе данных применен метод искусственного увеличения выборки путем создания новых изображений на основе существующих данных, который включал в себя такие операции как горизонтальное и вертикальное отражение, поворот на заданный угол, случайное добавления шума, размытие по Гауссу. Для сбора данных использован квадрокоптер DJI Phantom 2 с подвесом DJI Zenmuse Gimbal с камерой GoPro HD HERO3. Для оценки качества работы модели YOLOv7 при распознавании заданных классов использованы известные метрики Precision (точность), Recall (полнота), AP (средняя точность) и F-score (F-мера). Проведена оценка показателей при распознавании как индивидуальных классов, так и по всем классам в среднем. Анализ полученных результатов показал, что средняя абсолютная процентная ошибка распознавания изображений тестовой выборки всех классов составила 8,1 %. Наиболее сложным для распознавания оказался класс «ovary_strawberry» – завязь земляники садовой, средняя абсолютная процентная ошибка которого составила 13 %. Средняя точность подсчета по всем классам при использовании модели YOLOv7 в сравнении с подсчетом экспертами-агрономами составила 90,2 %. Использование полученных в полевых условиях данных по каждому компоненту продуктивности растений и коэффициентов соотношений между ними позволит определять потенциальную и фактическую урожайность, а также осуществлять управление этой урожайностью, руководствуясь биологической продуктивностью различных сортов земляники садовой.

Ключевые слова: сверточная нейронная сеть, трансферное обучение, классификация данных, распознавание, земляника садовая.

Для цитирования: Кутырёв А. И., Филиппов Р. А. Распознавание генеративных частей земляники садовой с использованием сверточной нейронной сети // Таврический вестник аграрной науки. 2023. № 2(34). С. 72–86. EDN: IUDJFX. DOI 10.5281/zenodo.8271986.

For citation: Kutyrav A. I., Filippov R. A. Recognition of generative parts of *Fragaria × ananassa* using convolutional neural network (CNN) // Taurida Herald of the Agrarian Sciences. 2023. No. 2(34). P. 72–86. EDN: IUDJFX. DOI 10.5281/zenodo.8271986.

Введение

Земляника садовая (*Fragaria × ananassa*) является одной из наиболее распространённых и ценных ягодных культур благодаря высокой питательной ценности, скороплодности и высокому урожаю с единицы площади, а также длительному периоду плодоношения. На её долю приходится до 72 % валового

производства всех ягодных культур в мире [1–3].

Потенциальная урожайность земляники садовой определяется такими показателями как количество цветоносов, цветковых почек, завязей и незрелых плодов. В настоящее время для оценки потенциальной урожайности проводят визуальные осмотры насаждений экспертами-агрономами, результаты которых сопоставляют с данными по урожайности за несколько предыдущих лет [4–6]. Визуальный осмотр требует высокой квалификации специалистов и значительных затрат времени, что обусловлено необходимостью тщательного ручного подсчета всех компонентов генеративных частей растения земляники садовой. Применяемый метод проведения наземных осмотров имеет значительные ограничения в точности определения ключевых фаз развития растений земляники. Недостатки данного метода могут быть решены с помощью автоматических инструментов классификации и обработки цифровых данных с RGB-камер [7–9].

Важным элементом планирования технологических процессов и определения объемов производства плодов земляники садовой является своевременный мониторинг состояния растений, а также текущей и потенциальной урожайности. Применение современных технологий мониторинга насаждений, основанных на использовании технологий машинного обучения и компьютерного зрения, позволит оптимизировать процесс возделывания земляники садовой, снизить потери и улучшить качество товарной продукции, обеспечить повышение эффективности использования материальных и трудовых ресурсов [10].

Для более быстрого и точного процесса подсчета генеративных частей земляники садовой предлагается автоматизировать данный процесс путём применения алгоритмов машинного обучения, таких как сверточные нейронные сети (CNN).

Анализ исследований по применению методов машинного обучения для распознавания биологических объектов показал, что среди существующих моделей нейронных сетей, таких как SSD (Single Shot MultiBox Detector), Faster R-CNN (Region-based Convolutional Neural Networks), RetinaNet, EfficientDet, Mask R-CNN наиболее производительной моделью является современная модель YOLOv7 (You Only Look Once). Архитектура модели YOLOv7 позволяет распознавать объекты в режиме реального времени. Модель использует сверточные нейронные сети для извлечения признаков и детектирования объектов, позволяет обнаруживать множество объектов на изображении и присваивать им соответствующие классы и ограничивающие рамки. Модель YOLOv7 устойчива к изменениям освещения, размытия, теням и другим условиям, что делает её эффективной в различных сценариях обнаружения объектов. Она позволяет обрабатывать изображения со скоростью до 244 кадров в секунду на GPU (графический процессор) или до пяти кадров в секунду на CPU (центральный процессор). Используемая модель YOLOv7 содержит 227 слоев, включая семь блоков CSPDarknet53, 4 блока SPP (Spatial Pyramid Pooling) и три слоя YOLO. Модель обеспечивает высокую точность распознавания объектов благодаря использованию техники машинного обучения, такой как обучение на большом объеме данных (Big Data) [12, 13].

Цель исследований – разработка метода сбора, анализа и классификации данных для распознавания генеративных частей земляники садовой, подсчета их количества на изображениях на основе свёрточной нейронной сети YOLOv7 с использованием трансферного обучения (Transfer Learning).

Материалы и методы исследований

В исследованиях использован метод трансферного обучения (Transfer Learning), который заключается в адаптации предварительно обученной модели

YOLOv7 на датасете COCO (Common Objects in Context) для обучения на новых данных. Данный метод позволяет использовать знания модели, полученные при решении одной задачи, для решения другой более узкой задачи, что позволяет ускорить процесс обучения для распознавания объектов в новой области или с новыми характеристиками и повысить точность распознавания объектов [14, 15].

Для сбора набора данных (изображений) использован квадрокоптер DJI Phantom 2 с подвесом DJI Zenmuse Gimbal с камерой GoPro HD HERO3 Edition (CHDX-301). Разрешение матрицы 12МП, разрешение видео – 4096×2160 Пикс (4K Ultra HD), фокусное расстояние камеры фиксированное – 2,77 мм (широкоугольный объектив). Сбор данных проведен в ЗАО «Совхоз имени Ленина», сорт земляники садовой Зенга-Зенгана. Маршрут полета квадрокоптера включал в себя движение над рядами земляники садовой челночным способом, на высоте не более 2 м. С помощью квадрокоптера был собран набор данных в количестве 2000 изображений. Освещение во время съемки составляло от 60000 лк до 110000 лк.

Для подготовки набора данных для обучения модели YOLOv7 проведено аннотирование полученных изображений с использованием сервиса CVAT (Computer Vision Annotation Tool). Аннотация изображений проведена экспертами путем выделения объектов в прямоугольную рамку и дальнейшей классификации (выбора класса к которому принадлежит объект в рамке).

Выделено четыре класса генеративных образований земляники садовой для обучения нейронной сети: цветы (класс «flower_strawberry»), завязь (класс «ovary_strawberry»), незрелая ягода (класс «unripe_strawberry»), зрелая ягода (класс «ripe_strawberry»). К классу цветов относили генеративные образования с белыми лепестками, к классу завязь – генеративные образования с зачатком плода размером не более 1 см в длину, к классу незрелой ягоды – неспелый плод длиной больше одного сантиметра зеленого, белого и бело-розового цветов, зрелой ягоды – плоды полностью окрашенные в розовый или красный цвета. Формат JSON (JavaScript Object Notation) использован для хранения данных о разметке на изображениях растений земляники садовой (рисунок 1).




Рисунок 1 – Аннотирование изображений в сервисе CVAT

Для обеспечения баланса классов в используемом наборе данных применен метод Oversampling (искусственное увеличение выборки), путем создания новых примеров на основе существующих данных. Использован онлайн сервис Roboflow синтетической генерации данных (synthetic data generation). Аугментация данных включала в себя такие операции как горизонтальное и вертикальное отражение (flip: horizontal, vertical), поворот на угол, выбранный в пределах между -15° и $+15^\circ$ (rotation: between -15° and $+15^\circ$), случайное добавления шума, введение изменений в пиксели изображения в количестве до 5 % (noise: up to 5 % of pixels) и добавление размытия по Гауссу (blur: 10 px) (рисунок 2) [16].



Рисунок 2 – Примеры аугментации изображений используемого набора данных

Процесс аугментации изображений позволил увеличить объем выборки до 6000 изображений. Для обеспечения оптимального баланса классов проведено разделение набора данных в необходимом процентном соотношении на тренировочный, валидационный и тестовый наборы, что необходимо для оценки и контроля производительности модели на независимых данных. Тренировочный набор состоит из 4200 изображений (70 % от общего набора данных). Эти изображения используют для обучения модели. Во время тренировки модель анализирует эти изображения и обновляет свои веса и параметры, чтобы научиться распознавать и классифицировать объекты. Валидационный набор состоит из 1200 изображений (20 % от общего набора данных). Эти изображения используют для оценки производительности модели во время обучения. В процессе обучения модели на тренировочных данных, валидационный набор данных используют для проверки точности модели и настройки гиперпараметров, таких как скорость обучения, количество эпох и так далее. Тестовый набор состоит из 600 изображений (10 % от общего набора данных). Эти изображения не используют в процессе обучения и настройки модели. Они служат для окончательной оценки производительности модели после завершения обучения. На тестовом наборе данных оценивается способность модели классифицировать объекты, которые она не использовала во время обучения и валидации.

Для обучения модели YOLOv7 на созданной выборке данных использовано 250 эпох, каждая из которых состояла из нескольких итераций (batch). Размер итераций (batch size) на каждой эпохе составлял 16. Количество эпох установлено экспериментальным методом с учетом размера выборки данных, сложности

используемой модели, архитектуры модели и других параметров. Обновление параметров модели (в том числе весовых коэффициентов) после каждой эпохи производилось автоматически в процессе обучения модели с помощью алгоритма оптимизации (стохастический градиентный спуск, SGD), который настраивает веса модели на основе градиентов функции потерь (ошибки модели) и применяет их для обновления весов.

Для оценки качества работы модели YOLOv7 при распознавании объектов использованы известные метрики – Precision (точность), Recall (полнота), AP (средняя точность) и F-score (F-мера). Проведена оценка показателей при распознавании как индивидуальных классов (бинарная классификация, Binary Classification), так и по всем классам в среднем (мультиклассовая) классификация, Multi-Class Classification) (таблица 1) [17, 18]. Величина tp_i показывает количество объектов класса i , которые были правильно распознаны моделью, fp_i – количество объектов, которые модель неправильно отнесла к классу i , fn_i – количество объектов i -го класса, которые не были распознаны.

Таблица 1 – Метрики используемые для анализа качества работы модели YOLOv7 при распознавании заданных классов

Метрика	Формула
При распознавании индивидуальных классов	
Precision (точность),	$\frac{tp_i}{tp_i + fp_i}$
Recall (полнота)	$\frac{tp_i}{tp_i + fn_i}$
AP (Average Precision)	$\int_{r=0}^1 Precision_i(r) dr$
F-score (F-мера)	$2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$
При распознавании всех заданных классов	
Average recall (средняя точность)	$\frac{\sum_{i=1}^n Precision_i}{n}$
Average precision (средняя полнота)	$\frac{\sum_{i=1}^n Recall_i}{n}$
mAP (mean average precision)	$\frac{(AP_1 + AP_2 + \dots + AP_n)}{n}$
Average F-score (средняя F-мера)	$\frac{\sum_{i=1}^n 2 \cdot \frac{Precision_i \cdot Recall_i}{Precision_i + Recall_i}}{n}$

Метрика точности показывает долю правильно распознанных объектов класса i относительно всех объектов, которые модель отнесла к данному классу. Чем выше точность, тем меньше ложноположительных результатов, то есть объектов, которые модель неправильно отнесла к классу i . Полнота показывает, какую долю объектов данного класса из общего числа объектов алгоритм смог распознать. Метрика средней точности использована для оценки производительности алгоритма классификации и распознавания объектов. Она определена путем нахождения площади под кривой «точность–полнота» (Precision-Recall curve), которая строится по результатам работы алгоритма. Для определения среднего гармонического значения между precision и recall использована метрика F1-score. Для анализа среднего показателя AP по всем классам использована метрика mAP (mean average precision), которая позволяет оценить общее качество работы алгоритма по всем классам объектов.

Для оценки точности прогноза идентификации генеративных частей земляники садовой проведен расчет средней абсолютной ошибки (Mean Absolute Percentage Error, MAPE) анализируемой модели нейронной сети YOLOv7, с использованием формулы 1:

$$MAPE = \frac{1}{n} \sum_{i=1}^K \left| \frac{\Phi_i - \Pi_i}{\Phi_i} \right| \quad (1)$$

где Φ_i – фактическое количество распознанных классов на тестовой выборке, шт. (классифицированных визуальным методом экспертами-агрономами), Π_i – количество распознанных классов, верно идентифицированных с помощью модели сверточной нейронной сети, шт.

Общая схема проведения исследований представлена на рисунке 3.

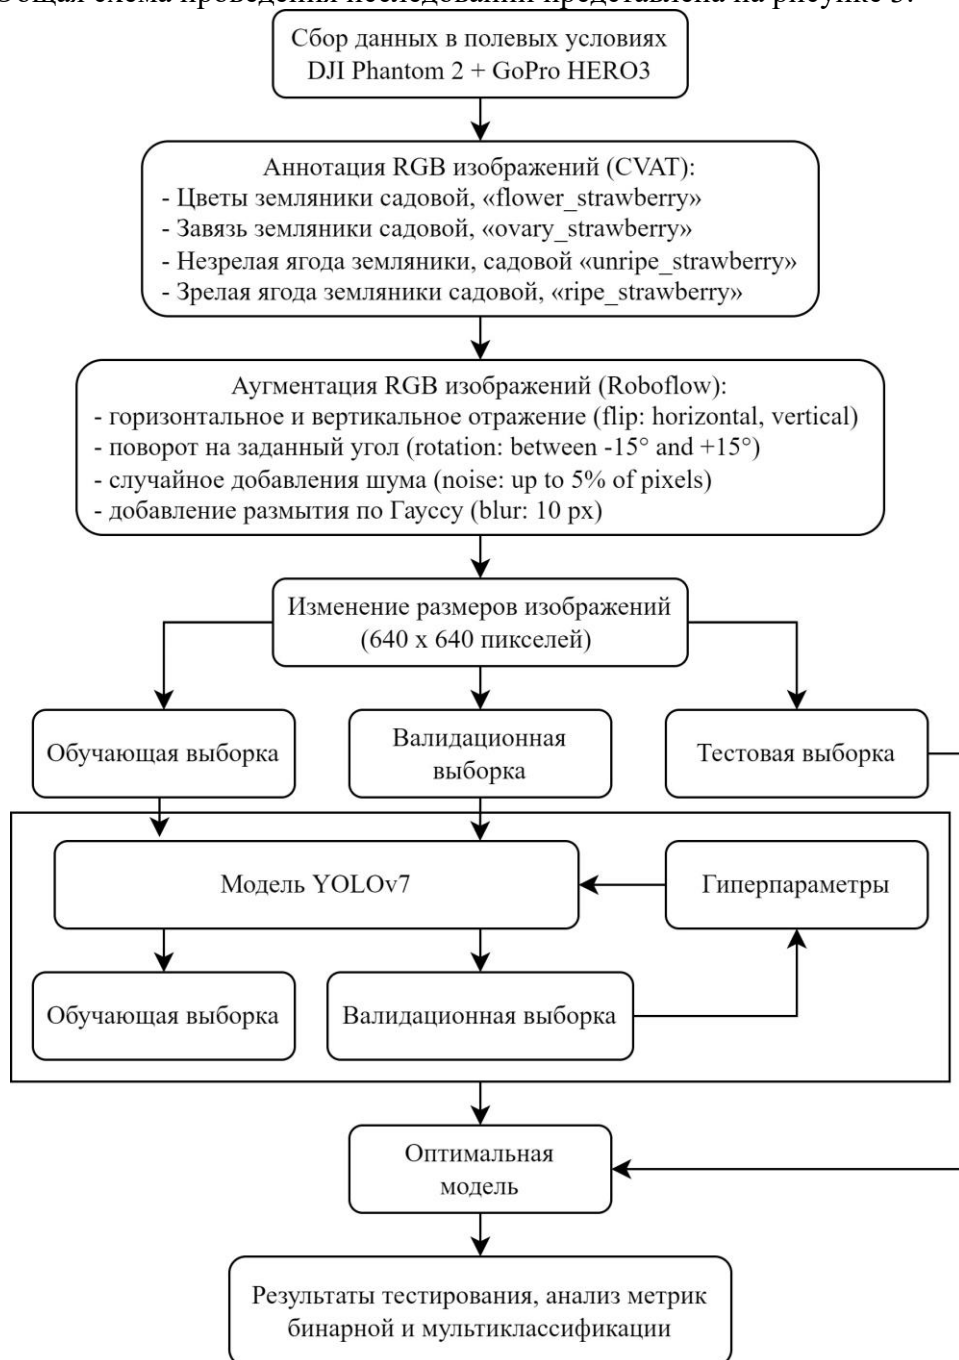


Рисунок 3 – Общая схема проведения исследований

Для обучения нейронной сети и проведения исследований использована компьютерная система, оснащённая процессором Intel Core i9-10900X с 10 ядрами и 20 виртуальными потоками. Для ускорения процесса обучения использованы две видеокарты NVIDIA GeForce RTX 2080 Ti, способных обрабатывать большой объем данных параллельно. Материнская плата GIGABYTE X299 UD4 Pro была использована для обеспечения высокой производительности системы. Для хранения данных, ускорения процесса загрузки данных использован накопитель SSD Intel PCI-E 1Tb 660P. Объем оперативной памяти системы составлял 32GB, использованы модули Kingston DDR4 DIMM.

Результаты и их обсуждение

Проведено обучение модели YOLOv7. Результаты распознавания заданных классов на изображениях представлены на рисунке 4.



Рисунок 4 – Результаты распознавания заданных классов на изображениях

На графике Precision-Recall (рисунок 5) представлена полученная зависимость точности и полноты при изменении порога (мера сходства между объектом и классами). Построенная кривая позволяет оценить качество классификации изображений с помощью модели YOLOv7 в зависимости от выбранного порога.

Анализ графика Precision-Recall позволил определить оптимальный порог классификации 0,58, который обеспечивает наилучшее соотношение между точностью и полнотой для заданных классов.

Для оценки достоверности прогнозов модели и их соответствия фактическим значениям классов были построены Precision-Confidence и Recall-Confidence кривые (рисунок 6 а, 6 б). Precision-Confidence кривая позволила оценить точность предсказаний модели в зависимости от уверенности, с которой она делает свои предсказания, тогда как Recall-Confidence кривая позволила оценить полноту

предсказаний модели для положительного класса при различных значениях уверенности.






Рисунок 5 – Кривая оценки точности и полноты Precision-Recall



а



б

Рисунок 6 – Кривые оценки уверенности предсказаний модели и определения их соответствия истинным значениям классов

Построенная кривая F1-score-Confidence позволила оценить влияние изменения уровня уверенности модели на метрики точности и полноты, а также выбрать оптимальный порог для классификации с уровнем 0,54 (рисунок 7). Полученный график позволил оценить чувствительность модели, реакцию на наличие «шума» на изображениях.




Рисунок 7– Кривые метрики F1-score-Confidence

Результаты расчета метрик при распознавании индивидуальных классов и по всем классам в среднем (мультиклассовая классификация, Multi-Class Classification) представлены в таблице 2.

Таблица 2 – Результаты расчетов метрик бинарной и мультиклассовой классификации

Классификатор	Precision (точность)	Recall (полнота)	mAP@0,5	F-score (F-мера)
Цветы земляники садовой / «flower_strawberry»	0,757	0,646	0,679	0,685
Завязь земляники садовой / «ovary_strawberry»	0,574	0,492	0,47	0,512
Незрелая ягода земляники садовой / «unripe_strawberry»	0,669	0,564	0,612	0,593
Зрелая ягода земляники садовой / «ripe_strawberry»	0,523	0,692	0,64	0,544
Average (все классы)	0,631	0,598	0,6	0,583

Анализ кривых Precision-Epoch, Recall-Epoch, mAP-Epoch позволил определить количество эпох (52), когда модель достигает наилучшего сочетания точности и полноты, запятая и выбрать гиперпараметры для достижения наилучшей производительности модели и максимальной точности детектирования заданных классов, выделения областей на изображениях (рисунок 8). Общее время обучения модели YOLOv7 при использовании GPU составило 4 ч 15 мин 24 сек.

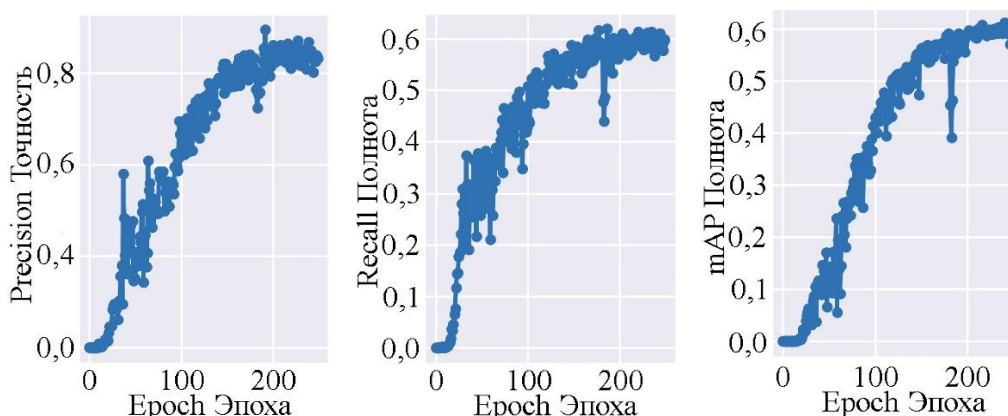


Рисунок 8 – Графики зависимости метрик Precision, Recall и mAP от эпохи обучения модели YOLOv7

Проведен анализ средней абсолютной процентной ошибки (MAPE, Mean Absolute Percentage Error) обученной модели YOLOv7 при распознавании всех заданных классов растений земляники садовой на изображениях тестового набора данных. Результаты расчетов средней абсолютной процентной ошибки модели нейронной сети YOLOv7 представлены в таблице 3.

Анализ полученных результатов показал, что средняя абсолютная процентная ошибка распознавания изображений тестовой выборки всех классов составила 8,1 %. Наиболее сложным для распознавания оказался класс «ovary_strawberry» – завязь земляники садовой, средняя абсолютная процентная ошибка которого составила 13 %.

Для оценки возможности мониторинга предлагаемым методом циклов роста и динамики развития растений земляники садовой проведен анализ изображений рядов в различные периоды времени. В таблице 4 представлены результаты сравнения количества распознанных объектов по классам, которые были подсчитаны

визуальным методом экспертами-агрономами и с помощью обученной модели сверточной нейронной сети YOLOv7 в результате проведенного распознавания генеративных частей, анализа и классификации данных в период с 25.05.2022 по 05.06.2022.

Таблица 3 – Результаты расчетов средней абсолютной процентной ошибки модели нейронной сети YOLOv7

Классификатор	Количество изображений тестовой выборки, шт.	Количество изображений верно классифицированных с помощью обученной модели YOLOv7, шт.	Средняя абсолютная ошибка (Mean Absolute Percentage Error, MAPE), %
Цветы земляники садовой / «flower_strawberry»	600	569	5,2
Завязь земляники садовой / «ovary_strawberry»		522	13,0
Незрелая ягода земляники садовой / «unripe_strawberry»		553	7,8
Зрелая ягода земляники садовой / «ripe_strawberry»		562	6,3
Average (все классы в среднем)		551	8,1

Таблица 4 – Результаты проведения полевых исследований по распознаванию генеративных частей земляники садовой предлагаемым методом

Дата сбора данных	Класс	Подсчет экспертами-агрономами (визуальный метод), шт.	Подсчет с помощью обученной модели YOLOv7, шт.	Средняя абсолютная ошибка (Mean Absolute Percentage Error, MAPE), %
25.05.2022	Цветы земляники садовой / «flower_strawberry»	1880	1757	6,5
	Завязь земляники садовой / «ovary_strawberry»	987	842	14,7
	Незрелая ягода земляники садовой / «unripe_strawberry»	412	374	9,2
	Зрелая ягода земляники садовой / «ripe_strawberry»	47	44	6,4
Всего распознано объектов	Все классы	831,5	754,2	9,2
05.06.2022	Цветы земляники садовой / «flower_strawberry»	1345	1245	7,4
	Завязь земляники садовой / «ovary_strawberry»	1467	1238	15,6
	Незрелая ягода земляники садовой / «unripe_strawberry»	786	698	11,2
	Зрелая ягода земляники садовой / «ripe_strawberry»	324	301	7,1
Всего распознано объектов	Все классы	980,5	870,5	10,3

Средняя точность подсчета по всем классам при использовании модели YOLOv7 в сравнении с подсчетом экспертами-агрономами составила 90,2 %. Анализ проведенных полевых исследований показал, что с уменьшением количества цветов в рядах садовых насаждений наблюдается увеличение ложноотрицательных результатов распознавания модели. Это объясняется тем, что при уменьшении количества цветов наблюдается увеличение количества завязей, незрелых и зрелых плодов, а также меняется количество и размер листьев, что приводит в свою очередь к увеличению зон перекрытия объектов, в результате чего затрудняется их распознавание, в конечном итоге приводя к ошибкам в подсчете.

В результате проведенных исследований разработан метод распознавания генеративных частей земляники садовой с применением алгоритмов машинного обучения. Для обеспечения необходимой точности распознавания определены минимальные требования к сверточной нейронной сети. Сбор набора изображений генеративных частей земляники садовой должен быть проведен путем фотографирования их в рядах насаждений RGB камерой, разрешение изображений должно составлять не менее 1920×1080 пикселей. Расстояние до объекта съемки должно находиться в диапазоне от 1,0 до 2,5 м. Освещение при сборе данных должно быть в диапазоне от 50000 лк до 150000 лк. Тренировочный набор данных должен включать в себя не менее 2000 изображений, в том числе изображения, полученные путем применения операции аугментации. Для качественной работы модели метрика mAP оценки общего качества работы алгоритма по всем классам объектов должна быть не менее 0,5.

Для распознавания генеративных частей земляники садовой других сортов в дальнейших исследованиях планируется использование метода инкрементного обучения (incremental learning), позволяющего проводить автоматическое дообучение ранее обученной модели на новом наборе данных в процессе её работы в режиме реального времени. Метод позволит модели постепенно обучаться на новых данных, сохраняя уже полученные знания и адаптируясь к новым условиям.

Выводы

Анализ результатов исследований показал, что распознавание генеративных частей земляники садовой на промышленной плантации, проведенное с использованием квадрокоптера DJI Phantom 2 с подвесом DJI Zenmuse Gimbal с камерой GoPro HD HERO3 с применением для обработки полученных данных свёрточной нейронной сети YOLOv7, позволит вести количественный учет цветков, завязей, незрелых и зрелых ягод со средней точностью 90,2 % при высоте полета не более 2 м.

Анализ полученных графиков, метрик бинарной и мультиклассовой классификации по оценке качества работы обученной модели нейронной сети YOLOv7 позволил установить оптимальные параметры настройки, выбрать порог уверенности, на котором модель показывает оптимальную точность и полноту, сбалансированную с количеством распознанных объектов. Определены конфигурации (гиперпараметры) алгоритма машинного обучения модели для распознавания заданных классов земляники садовой: скорость обучения (learning rate) – 0,01 LR (learning rate), количество эпох (epochs) – 250, размер мини-пакета (batch size) – 16.

Искусственное увеличение объема обучающей выборки (изображений генеративных частей земляники), использование таких инструментов как горизонтальное и вертикальное отражение, поворот на заданный угол, случайное добавления шума и добавление размытия по Гауссу позволило повысить качество

обучения модели сверточной нейронной сети YOLOv7 и адаптировать систему к реальным условиям.

В дальнейших исследованиях рекомендуется применение стереокамер высокого разрешения, что позволит дополнительно повысить точность распознавания благодаря возможности определения размерных параметров плодов земляники садовой и построения 3D-моделей карт высотности с помощью фотограмметрии. Регулярный цифровой мониторинг с применением методов машинного обучения и цифровых камер позволит автоматически формировать задания для наземной техники или беспилотных летательных аппаратов, принимать оптимальные управленческие решения в режиме реального времени при возделывании земляники садовой. Использование полученных в полевых условиях данных по каждому компоненту продуктивности растений и коэффициентов соотношений между ними позволит определять потенциальную и фактическую урожайность, а также осуществлять управление этой урожайностью, руководствуясь биологической продуктивностью различных сортов земляники садовой.

Литература

1. 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.
2. Chiomento J. L.T., Lima Junior E. P., D'Agostini M., De Nardi F.S., Trentin Th. dos S., Dornelles G. A., Huzar-Novakowski J., Calvete E.O. Horticultural potential of nine strawberry cultivars by greenhouse production in Brazil: a view through multivariate analysis // Scientia Horticulturae. 2021. Vol. 279. Art. No. 109738. DOI: 10.1016/j.scienta.2020.109738.
3. Massa G. D., Chase E., Santini J. B., Mitchell C. A. Temperature affects long-term productivity and quality attributes of day-neutral strawberry for a space life-support system // Life Sciences in Space Research. 2015. Vol. 5. P. 39–46. DOI: 10.1016/j.lssr.2015.04.003.
4. Лапшин В. И. Результаты оценки отборных форм земляники по урожаю и качеству ягод // Научные труды Северо-Кавказского федерального научного центра садоводства, виноградарства, виноделия. 2019. № 23. С. 80–83. DOI: 10.30679/2587-9847-2019-23-80-83.
5. Махмарасулов С. С., Енилеев Н. Ш., Султонов К. С. Морфо-биологические и продуктивные особенности сортов земляники садовой (*Fragaria* × *ananassa* Duch. ex Weston) // Аграрная наука. 2020. №1. С. 67–70. DOI: 10.32634/0869-8155-2020-334-1-67-7.
6. Марченко Л. А. Земляника садовая: оценка отечественного сортимента и направления селекции // Аграрный вестник Урала. 2020. № 12 (203). С. 50–60. DOI: 10.32417/1997-4868-2020-203-12-50-60.
7. Khort D., Kutyrav A., Smirnov I., Osypenko V., Kiktev N. Computer vision system for recognizing the coordinates location and ripeness of strawberries // Communications in Computer and Information Science. 2020. No. 1158. P.334–343. DOI: 10.1007/978-3-030-61656-4_22.
8. Zhou H., Ou J., Meng P., Tong J., Ye H., Li Z. Research on kiwi fruit flower recognition for efficient pollination based on an improved YOLOv5 algorithm // Horticulturae. 2023. No. 9. Art. No. 400. DOI: 10.3390/horticulturae9030400.
9. 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. Т. 67. № 1(38). С. 133–141. DOI: 10.22314/2658-4859-2020-67-1-133-141.
10. Zheng C., Abd-Elrahman A., Whitaker V. Remote sensing and machine learning in crop phenotyping and management, with an emphasis on applications in strawberry farming // Remote Sens. 2021. No.13. Art. No. 531. DOI: 10.32417/10.3390/rs13030531.
11. Zheng H., Cheng T., Zhou M., Li D., Yao X., Tian Y., Cao, W., Zhu Y. Improved estimation of rice aboveground biomass combining textural and spectral analysis of UAV imagery // Precis. Agric. 2019. No. 20. P. 611–629. DOI: 10.1007/s11119-018-9600-7.
12. Xie C., Yang C. A review on plant high-throughput phenotyping traits using UAV-based sensors // Comput. Electron. Agric. 2020. No.178. Art. No. 105731. DOI: 10.1016/j.compag.2020.105731.
13. 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 J. Photogramm. Remote Sens. 2020. No. 163. 171–186. DOI: 10.1016/j.isprsjprs.2020.02.021.

14. Behmann J., Mahlein A. K., Rumpf T., Römer C., Plümer L. A review of advanced machine learning methods for the detection of biotic stress in precision crop protection // *Precis. Agric.* 2015. No. 16. P. 239–260. DOI: 10.1007/s11119-014-9372-7.
15. Andrejko E., Valley S. Deep Learning in Agriculture // *Comput. Electron. Agric.* 2018. No.147. P. 70–90.
16. Sa I., Ge Z., Dayoub F., Upcroft B., Perez T., McCool C. DeepFruits: a fruit detection system using deep neural networks // *Sensors.* 2016. No.16. Art. No. 1222. DOI: 10.3390/s16081222.
17. 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. No. 13(13). Art. No. 2450. DOI: 10.3390/rs13132450.
18. Maxwell A. E., Warner T. A., Guillén L. A. Accuracy assessment in convolutional neural networkbased deep learning remote sensing studies – Part 2: recommendations and best practices // *Remote Sensing.* 2021. No. 13(13). Art. No. 2591. DOI: 10.3390/rs13132591.

References

1. Marchenko L. A. Productivity of garden strawberry and breeding possibilities to improve it // *Siberian Herald of Agricultural Science.* 2021. No. 51(3). P. 65–74. DOI: 10.26898/0370-8799-2021-3-7.
2. Chiomento J. L.T., Lima Junior E. P., D'Agostini M., De Nardi F. S., Trentin Th. dos S., Dornelles G. A., Huzar-Novakowski J., Calvete E. O. Horticultural potential of nine strawberry cultivars by greenhouse production in Brazil: a view through multivariate analysis // *Scientia Horticulturae.* 2021. Vol. 279. Art. No. 109738. DOI: 10.1016/j.scienta.2020.109738.
3. Massa G. D., Chase E., Santini J. B., Mitchell C. A. Temperature affects long-term productivity and quality attributes of day-neutral strawberry for a space life-support system // *Life Sciences in Space Research.* 2015. Vol. 5. P. 39–46. DOI: 10.1016/j.lssr.2015.04.003.
4. Lapshin V. I. Results of assessing the strawberry selected forms on the yield and quality of berries // *Scientific works of North Caucasian Federal Scientific Center of Horticulture, Viticulture, Wine-making.* 2019. No. 23. P. 80–83. DOI: 10.30679/2587-9847-2019-23-80-83.
5. Makhmarasulov S. S., Enileev N. Sh., Sulonov K. S. Morpho-biological and productive features of strawberry varieties (*Fragaria* × *ananassa* Duch. ex Weston) // *Agrarian science.* 2020. No. 1. P.67–70. DOI: 10.32634/0869-8155-2020-334-1-67-70.
6. Marchenko L. A. Strawberry: evolution of the domestic assortment and direction of selection // *Agrarian Bulletin of the Urals.* 2020. No. 12(203). P. 50–60. DOI: 10.32417/1997-4868-2020-203-12-50-60.
7. Khort D., Kuttyrev A., Smirnov I., Osypenko V., Kiktev N. Computer vision system for recognizing the coordinates location and ripeness of strawberries // *Communications in Computer and Information Science.* 2020. No. 1158. P. 334–343. DOI: 10.1007/978-3-030-61656-4_22.
8. Zhou H., Ou J., Meng P., Tong J., Ye H., Li Z. Research on kiwi fruit flower recognition for efficient pollination based on an improved YOLOv5 algorithm // *Horticulturae.* 2023. No. 9. Art. No. 400. DOI: 10.3390/horticulturae9030400.
9. Khort D. O., Kuttyrev A. I., Smirnov I. G., Filippov R. A., Vershinin R. V. Developing algorithms for a berry recognition system used in robotized harvesting of garden strawberry // *Electrical Engineering and Electrical Equipment in Agriculture.* 2020. Vol. 67. No. 1(38). P. 133–141. DOI: 10.22314/2658-4859-2020-67-1-133-141.
10. Zheng C., Abd-Elrahman A., Whitaker V. Remote sensing and machine learning in crop phenotyping and management, with an emphasis on applications in strawberry farming // *Remote Sens.* 2021. No.13. Art. No. 531. DOI: 10.32417/ 10.3390/rs13030531.
11. Zheng H., Cheng T., Zhou M., Li D., Yao X., Tian Y., Cao W., Zhu Y. Improved estimation of rice aboveground biomass combining textural and spectral analysis of UAV imagery // *Precis. Agric.* 2019. No.20. P. 611–629. DOI: 10.1007/s11119-018-9600-7.
12. Xie C., Yang C. A review on plant high-throughput phenotyping traits using UAV-based sensors // *Comput. Electron. Agric.* 2020. No.178. Art. No. 105731. DOI: 10.1016/j.compag.2020.105731.
13. 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 J. Photogramm. Remote Sens.* 2020. No. 163. P. 171–186. DOI: 10.1016/j.isprsjprs.2020.02.021.
14. Behmann J., Mahlein A.K., Rumpf T., Römer C., Plümer L. A review of advanced machine learning methods for the detection of biotic stress in precision crop protection // *Precis. Agric.* 2015. No.16. P. 239–260. DOI: 10.1007/s11119-014-9372-7.
15. Andrejko E., Valley S. Deep Learning in Agriculture // *Comput. Electron. Agric.* 2018. No.147. P. 70–90.
16. Sa I., Ge Z., Dayoub F., Upcroft B., Perez T., McCool C. DeepFruits: a fruit detection system using deep neural networks // *Sensors.* 2016. No.16. Art. No. 1222. DOI: 10.3390/s16081222.

17. 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. No. 13(13). Art. No. 2450. DOI: 10.3390/rs13132450.

18. Maxwell A. E., Warner T. A., Guillén L. A. Accuracy assessment in convolutional neural network-based deep learning remote sensing studies – Part 2: recommendations and best practices // Remote Sensing. 2021. No.13(13). Art. No. 2591. DOI: 10.3390/rs13132591.

UDC 631.171.004.3:004.932

Kutyrev A. I., Filippov R. A.

RECOGNITION OF GENERATIVE PARTS OF *FRAGARIA* × *ANANASSA* USING CONVOLUTIONAL NEURAL NETWORK (CNN)

Summary. *The article proposes a method for collecting, analyzing and classifying data for recognition of generative parts of Fragaria × ananassa using convolutional neural network (CNN). Transfer learning of the YOLOv7 convolutional neural network model was carried out on a data set with the allocation of four classes of development of generative formations. The research was carried out in 2022. As a result, a set of images (dataset) of flowers, ovaries, unripe and ripe berries was formed. To ensure the balance of classes in the data set used, the oversampling method was applied: new examples (images) based on existing data were created; these images were created by applying horizontal and vertical reflection, rotation by a given angle, random noise addition and Gaussian blur. To collect the data set, DJI Phantom 2 quadcopter with DJI Zenmuse Gimbal for GoPro HD HERO3 camera was used. To assess the quality of the YOLOv7 model when recognizing specified classes, well-known metrics Precision, Recall, AP (average precision) and F-score were used. An evaluation of the recognition indicators of both individual classes and for all classes on average was carried out. The analysis of the results showed that the mean absolute percentage error (MAPE) of image recognition of the test sample of all classes was 8.1 %. “Ovary strawberry” class was the most difficult to recognize; (MAPE reached the level of 13 %). The average accuracy of the calculation for all classes using the YOLOv7 model in comparison with the calculation by expert agronomists was 90.2 %. The use of data obtained in the field for each component of plant productivity and the coefficients of the ratios between them will allow determining the potential and actual yield, as well as to manage this yield depending on the biological productivity of various strawberry cultivars.*

Keywords: *convolutional neural network, transfer learning, data classification, recognition, Fragaria × ananassa.*

Кутырёв Алексей Игоревич, заведующий лабораторией интеллектуальных цифровых систем мониторинга, диагностики и управления процессами в сельскохозяйственном производстве, старший научный сотрудник, ФГБНУ «Федеральный научный агроинженерный центр ВИМ»; 109428, Россия, Москва, 1-й Институтский проезд, 5; e-mail: alexeykutyrev@gmail.com.

Филиппов Ростислав Александрович, ведущий научный сотрудник лаборатории машинных технологий для возделывания и уборки плодово-ягодных культур ФГБНУ «Федеральный научный агроинженерный центр ВИМ»; 109428, Россия, Москва, 1-й Институтский проезд, 5; e-mail: rostislav-filippov@yandex.ru.

Kutyrev Aleksey Igorevich, senior researcher, head of the Laboratory of intelligent digital systems for monitoring, diagnostics and process management in agricultural production, FSBSI “Federal Scientific Agroengineering Center VIM”; 5, 1st Institutskiy proezd, Moscow, 109428, Russia; e-mail: alexeykutyrev@gmail.com.

Filippov Rostislav Aleksandrovich, leading researcher of the Laboratory of machine technologies for cultivation and harvesting of fruit and berry crops, FSBSI “Federal Scientific Agroengineering Center VIM”; 5, 1st Institutskiy proezd, Moscow, 109428, Russia; e-mail: rostislav-filippov@yandex.ru.

Дата поступления в редакцию – 21.04.2023.

Дата принятия к печати – 21.05.2023.