

Применение сверточной нейронной сети для мониторинга состояния земляники садовой

© 2023. А. И. Кутырёв[✉], Р. А. Филиппов

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

В статье предложен метод повышения точности диагностирования недостатка кальция в растениях земляники садовой – применение алгоритмов машинного обучения, таких как сверточные нейронные сети (CNN), что позволяет обучить модель на наборе данных для качественного обнаружения признаков дефицита кальция на листьях. Собран набор данных (dataset) изображений здоровых листьев и с признаками недостатка кальция, использован способ искусственного увеличения объема обучающей выборки (image augmentation) путем горизонтального и вертикального отражения объектов на изображениях, поворота на заданный угол и случайного добавления «шума». Для обучения сверточной нейронной сети предложен алгоритм получения RGB-изображений с помощью роботизированной платформы. В качестве средства обнаружения признаков дефицита кальция на листьях земляники на изображениях использована современная модель нейронной сети YOLOv7. Определены гиперпараметры алгоритма машинного обучения модели YOLOv7 для распознавания областей поражения листьев земляники садовой, вызванных недостатком кальция. Для обучения модели YOLOv7 использован метод трансферного обучения (Transfer learning). Для оценки качества работы алгоритмов распознавания объектов использованы метрики mAP (mean average precision) и F1-score (F-мера), проведен расчет средней абсолютной ошибки (Mean Absolute Percentage Error, MAPE) рассматриваемой модели нейронной сети YOLOv7. Анализ полученных результатов показал, что модель YOLOv7 распознала класс «Calciumdeficiency» с показателем MAPE, равным 7,52 %. Расчетное значение метрики бинарной классификации mAP составило 0,454, метрики F1-score – 0,53. Результаты исследований показали, что своевременный мониторинг состояния земляники садовой на промышленной плантации, проведенный с использованием колесной роботизированной платформы с применением сверточной нейронной сети YOLOv7 для обработки полученных данных, позволит на ранних этапах развития патологии с высокой точностью до 94,43 % определить дефицит кальция в листьях растений земляники садовой.

Ключевые слова: трансферное обучение, машинное обучение, распознавание, роботизированная платформа, поражение листьев, искусственное увеличение выборки

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

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

Конфликт интересов: авторы заявили об отсутствии конфликта интересов.

Для цитирования: Кутырёв А. И., Филиппов Р. А. Применение сверточной нейронной сети для мониторинга состояния земляники садовой. Аграрная наука Евро-Северо-Востока. 2023;24(4):685-696.

DOI: <https://doi.org/10.30766/2072-9081.2023.24.4.685-696>

Поступила: 30.03.2023

Принята к публикации: 28.07.2023

Опубликована онлайн: 30.08.2023

Application of convolutional neural network for monitoring the condition of strawberries

© 2023. Alexey I. Kutyrev[✉], Rostislav A. Filippov

Federal Scientific Agroengineering Center VIM, Moscow, Russian Federation

The article proposes a method for improving the accuracy of diagnosing calcium deficiency in strawberry plants, suggests the use of machine learning algorithms, such as convolutional neural networks (CNN), which makes it possible to train a model on a data set for qualitative detection of signs of calcium deficiency in the leaves. A dataset of images of healthy leaves and leaves with signs of calcium deficiency was collected, the method of artificially increasing the volume of the training sample (image augmentation) was applied, by horizontal and vertical reflection of objects in the images, rotation by a given angle and random addition of «noise». To train a convolutional neural network, an algorithm for obtaining RGB images using a robotic platform is proposed. A modern model of the YOLOv7 neural network was used as a means of detecting the signs of calcium deficiency in the leaves of strawberry in the images. The configuration of the YOLOv7 machine learning algorithm for recognizing areas of damage to strawberry leaves caused by calcium deficiency has been determined. To train the YOLOv7 model, the Transfer learning method was used. To assess the quality of the object recognition algorithms, the metric mAP (mean average precision) – 0.454 was used, the metric F1-score (F-measure) – 0.53, the average absolute error (Mean Absolute Percentage Error, MAPE) of the analyzed model of the YOLOv7 neural network was calculated. The analysis of the results showed that the YOLOv7 model recognized the «Calciumdeficiency» class, with a MAPE index equal to 7.52 %. The analysis of the research results showed that timely monitoring of the condition of garden strawberries on an industrial plantation carried out using a wheeled robotic platform with the use of the YOLOv7 convolutional neural network for processing the data obtained will allow to determine calcium deficiency in the leaves of strawberry plants with high accuracy up to 94.43 % at the early stages of pathology development.

Keywords: transfer learning, machine learning, recognition, robotic platform, leaf damage, artificial increasing of sampling

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

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

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

For citations: Kutyrev A. I., Filippov R. A. Application of convolutional neural network for monitoring the condition of strawberries. *Agrarnaya nauka Evro-Severo-Vostoka* = Agricultural Science Euro-North-East. 2023;24(4):685-696. (In Russ.). DOI: <https://doi.org/10.30766/2072-9081.2023.24.4.685-696>

Received: 30.03.2023

Accepted for publication: 28.07.2023

Published online: 30.08.2023

Земляника садовая (*Fragaria x ananassa*) является одной из наиболее распространённой и имеющей высокую питательную ценность ягодной культурой, благодаря быстрому вступлению в плодоношение и раннему созреванию ягод. По данным FAOSTAT (Food and Agriculture Organization of the Nations)¹, в 2021 году валовой сбор ягод земляники садовой составил 237 200 тонн. По данным Росстата, в 2021 году площади возделывания ягодных культур в сельскохозяйственных организациях составили 15,8 тысяч гектара, из которых порядка 30 % занимала земляника садовая.

Продуктивность земляники садовой зависит от многих факторов, в том числе от правильных агротехнических мероприятий, своевременного мониторинга неблагоприятных факторов развития растений. Нарушение питания земляники садовой может привести к различным отклонениям в её развитии. Кальций является важным структурным компонентом клеточных мембран земляники садовой, дефицит которого приводит к общему разрушению структуры мембран и клеточных стенок. Дефицит кальция в растениях имеет очень наглядные визуальные признаки: ягоды становятся мельче, плотнее с более бледной окраской, проявляется «ожог», некроз и деформирование кончиков пораженных листьев, отмирание черешков листьев, в результате чего сокращается рост корней [1, 2]. Исследованиями ученых установлено, что недостаток кальция связан не столько с бедностью питательной среды, но и со сложностью перемещения кальция в самом растении [3, 4]. Кальций поглощается кончиками корней и перемещается с потоком транспирации в те его части, где наблюдается наибольшая степень испарения, например, в старые листья. Плоды и молодые листья пропускают меньшее количество воды и именно в этих тканях проявляются первые симптомы дефицита кальция [5, 6].

Из всех признаков недостаточного количества кальция раньше всего проявляется симптом «ожога» кончиков листьев. Исследованиями известных ученых установлено, что если

растения земляники садовой имеют менее 0,9 % кальция, то у 70-78 % молодых листьев будут наблюдаться признаки сморщенности и «ожогов» краёв листа, что приведёт к существенному сокращению площади питания листовой поверхности. Уменьшение площади питания листовой поверхности на более чем 30 % приведет к необратимым процессам развития растений. Достаточным для нормального развития растений земляники садовой является показатель кальция около 1,5 % от сухой ткани листа. Известны и другие причины «ожогов» листьев в растениях земляники садовой, такие как попадание гербицидов или распространение сокососущих вредителей, но наиболее распространенным является именно недостаток кальция [7, 8].

В настоящее время для борьбы с недостатком кальция используют комплекс агротехнических мероприятий, а именно правильное регулирование баланса влажности, условий освещённости и питания [9]. Если своевременно не устранить последствия недостатка кальция в растениях, то недобор урожая может достигнуть 10-22 %. В омертвевших частях листа может возникнуть микробная инфекция, что также является следствием недостатка кальция [10].

В связи с этим важным мероприятием в процессе возделывания земляники садовой является раннее диагностирование признаков недостатка кальция. При оценке тех или иных отклонений в развитии растений, а также поражения вредителями и болезнями применяют метод наблюдения и визуальной оценки экспертами-агрономами. Качество диагностирования зависит от квалификации специалиста и в случае ошибочной оценки приводит к большим потерям урожая. Для повышения точности диагностирования недостатка кальция в растениях земляники садовой предлагается применение алгоритмов машинного обучения, таких как нейронные сети (CNN), что позволит обучить модель на наборе данных для качественного

¹FAOSTAT Производство сельскохозяйственных культур. [Электронный ресурс]. URL: <https://www.fao.org/faostat/ru/#data/QCL> (дата обращения: 01.03.2023).

обнаружения признаков дефицита кальция на листьях земляники садовой. Автоматизация процесса раннего мониторинга, распознавания признаков недостатка кальция в отличие от визуального диагностирования экспертами-агрономами позволит повысить точность и скорость идентификации данных нарушений развития [11].

Существует множество различных типов нейронных сетей, которые могут быть применены в сельском хозяйстве для распознавания вредителей и болезней [12, 13, 14]. Проведенный в 2023 году в ФГБНУ ФНАЦ ВИМ анализ исследований показал, что в настоящее время одной из наиболее распространенных и эффективных моделей для распознавания болезней листьев является сверточная нейронная сеть (Convolutional Neural Networks, CNN) [15, 16]. Данные модели способны извлекать визуальные признаки из изображений, классифицировать их и автоматически находить связь между этими признаками [17].

Цель исследования – разработка метода мониторинга состояния растений земляники садовой, распознавания и классификации признаков дефицита кальция в растениях на изображениях листьев на основе сверточной нейронной сети YOLOv7 (You Only Look Once version 7) с использованием трансферного обучения (Transfer learning).

Научная новизна – разработан метод мониторинга состояния растений земляники садовой, включающий в себя способ сбора набора данных (dataset) изображений листьев земляники садовой (здоровых и с недостатком кальция) и искусственного увеличения объема обучающей выборки (image augmentation) для обучения сверточной нейронной сети YOLOv7; предложен алгоритм применения разработанной модели сверточной нейронной сети на промышленной плантации.

Материал и методы. В качестве средства обнаружения поражений листьев земляники при дефиците кальция на изображениях в проведенных нами исследованиях использована современная модель YOLOv7. Как и в предыдущих версиях моделей YOLO (YOLOv1-v5), YOLOv7 использует сверточные нейронные сети для обнаружения объектов. Однако модель YOLOv7 имеет ряд усовершенствований, которые позволяют ей обеспечивать более высокую точность и скорость работы. YOLOv7 использует более сложную архитектуру, которая включает в себя дополнительные блоки и более 100 сверточных слоев, комбинации сверточных

слоев, слоев объединения, слоев активации, слоев нормализации и слоев потерь.

Для обучения модели YOLOv7 использован метод трансферного обучения (Transfer learning). Метод заключается в использовании предварительно обученной модели для решения новой задачи. Знания, полученные моделью при решении изначальной задачи, переносятся на новую задачу, что позволяет улучшить производительность при ее решении. Используемая в исследованиях модель YOLOv7, предварительно обучена на стандартных наборах данных для задачи обнаружения объектов, таких как COCO (Common Objects in Context), ImageNet, Pascal VOC. Предварительное обучение позволяет уменьшить время обучения на целевой задаче распознавания поражений листьев земляники садовой и повысить производительность, поскольку модель уже обладает некоторой способностью к извлечению признаков, помимо этого предварительное обучение позволяет избежать риски переобучения модели.

Для обучения нейронной сети подготовлен набор данных (dataset) изображений пораженных листьев земляники садовой (класс «Calcium-deficiency»), недостаток кальция в листьях земляники садовой), листья земляники садовой без поражений (класс «Healthy leaves»). Включает в себя множество примеров (samples) – индивидуальные элементы данных и меток, определяющих категорию, класс и атрибуты, соответствующие каждому примеру. Сбор обучающего набора данных проводили путем фотографирования листьев земляники садовой RGB-камерой, установленной на роботизированной колёсной платформе, путём проезда роботизированной платформы в рядах промышленной плантации с западной и восточной стороны ряда. Платформа двигалась дискретно, останавливаясь напротив каждого растения, и делала несколько фотографий, затем движение продолжалось (рис. 1).

С помощью роботизированной платформы был собран набор данных в количестве 2000 шт. изображений. Использована камера Basler ace 2 с сенсером Sony IMX540 размером 14,6×12,6 мм, разрешение 24.4 МР, размер пикселя 2,74×2,74 мкм. Разрешение фотографий составляет 5665×4240 пикселей, фокусное расстояние 31 мм, диафрагменное число f/4. Фотографии были сделаны при ярком дневном свете, на расстоянии 10...40 см до растений. Фокусировку камеры на листьях проводили в автоматическом режиме. Освещение во время съемки составляло от 70000 до 100000 лк. Растения земляники на фотографиях имели здоровые листья и с признаками дефицита кальция.



Рис. 1. Процесс получения набора данных (изображений) с использованием роботизированной платформы /

Fig. 1. The process of obtaining a set of data (images) using a robotic platform

Для аннотирования набора данных для обучения алгоритмов машинного обучения использовано программное обеспечение с

открытым исходным кодом CVAT (Computer Vision Annotation Tool) (рис. 2).




Рис. 2. Разметка данных в программном обеспечении CVAT /

Fig. 2. Data markup in CVAT software

Разметка данных проведена с помощью инструмента Rectangle (прямоугольник). Для обозначения классов объектам на изображениях присвоены метки (Label). Метка «Calcium deficiency» использована для обозначения областей на листьях земляники с недостатком кальция. Для обеспечения точности и качества, устранения возможных ошибок, связанных с интерпретацией данных, разметка проведена

экспертным методом, данные размечены специалистами в соответствующей области знаний. Процесс разметки с помощью прямоугольников включал в себя такие этапы, как загрузка изображений в программное обеспечение, разметка данных (выделение в прямоугольник объектов), классификация данных (выбор класса, который был отмечен в прямоугольнике), применение метаданных (добавления атрибутов о названии

объекта, цвете, положении), экспортирование данных в формат, необходимый для использования в обучении моделей. Для выявления ошибок и несоответствий в разметке оценки, насколько хорошо размеченный объект совпадает с его реальным положением на изображении, проведена проверка на пересечение объектов, использована известная метрика IoU (Intersection over Union) [18]. Проведено вычисление координат прямоугольника (bounding box), который полностью окружает объект на изображении. Затем эти координаты использованы для вычисления площади выделенной области.

Метрика IoU рассчитана как отношение площади пересечения к площади объединения ограничивающего прямоугольника размеченного и реального объекта:

$$IoU = \frac{\text{intersection area}}{\text{union area}}, \quad (1)$$

где intersection area – площадь пересечения между прямоугольником размеченного объекта и прямоугольником реального объекта, dpi

(количество точек на дюйм); union area – площадь объединения прямоугольника размеченного и реального объекта, dpi.

Чем выше значение метрики IoU, тем более точно размечен объект.

Для того чтобы получить правильную оценку качества обучаемой модели, данные были сбалансированы во всех выборках методами Oversampling (увеличение выборки) и аугментации (image augmentation). Для увеличения объема обучающей выборки путем создания новых изображений на основе существующих использована онлайн-платформа RoboFlow, которая позволила провести преобразования изображений, используя такие инструменты, как горизонтальное и вертикальное отражение (зеркальное отражение объектов, flip: horizontal, vertical), поворот на угол, выбранный в пределах между -15° и $+15^\circ$ (rotation: between -15° и $+15^\circ$), случайное добавление шума, введение изменений в пиксели изображения в количестве до 5 % (noise: up to 5% of pixels) (рис. 3).

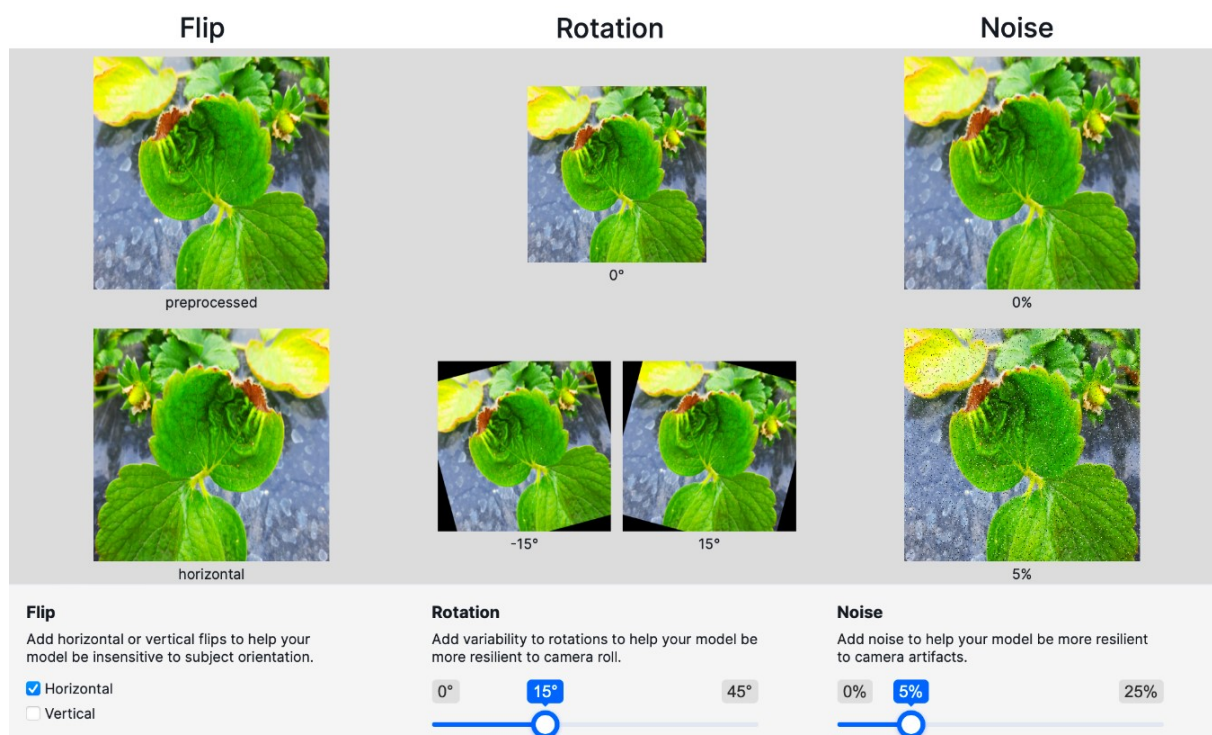


Рис. 3. Создание новых изображений на онлайн-платформе RoboFlow /
Fig. 3. Creating new images on the RoboFlow online platform

Добавление разнообразия в обучающие данные с помощью аугментации изображений позволяет модели нейронной сети адаптироваться и быть более устойчивой к «артефактам» и «шумам» на кадрах, что особенно важно для задачи, связанной с обработкой реальных данных, полученных в полевых условиях.

Аугментация изображений с помощью различных преобразований позволяет увеличить количество и разнообразие обучающих данных, что в свою очередь может помочь улучшить качество модели и повысить ее точность и надежность работы. Процесс аугментации позволил увеличить объем полученных данных

до 4800 изображений. В результате проведенных исследований, набор данных был поделен на обучающий – 4000 шт. изображений, валидационный – 400 шт. и тестовый – 400 шт. изображений. Размеченные данные, изображения здоровых и пораженных листьев земляники сохранены в формате .json (JavaScript Object Notation), который использован для обучения модели машинного обучения.

Для обучения модели использовали 100 эпох (epoch), где каждая состояла из нескольких итераций (batch), на каждой из которых модель обучалась на подвыборке тренировочных данных. Значение параметра batch, размера подвыборки данных, на которой модель обучается на каждой итерации при обучении модели, составило 16. Количество эпох было подобрано экспериментально, учитывая размер тренировочного набора данных и сложность модели. Большое количество эпох может привести к переобучению модели на тренировочных данных, что делает модель более чувствительной к шуму и случайным отклонениям в данных, что в свою очередь приводит к низким результатам распознавания объектов на новых данных. После каждой эпохи модель YOLOv7 корректировала веса (числовые параметры, определяющие число связей между нейронами), учитывая ошибки, которые были сделаны на предыдущих эпохах.

Для проведения исследований использовали вычислительную систему, оснащенную процессором Intel Core i9-10900X с 10 ядрами и 20 виртуальными потоками. Обучение модели проведено с помощью графического процессора GPU, задействованы две видеокарты NVIDIA GeForce RTX 2080 Ti, в качестве материнской платы использовали GIGABYTE X299 UD4 Pro. Для хранения данных применяли накопитель SSD Intel PCI-E 1Tb 660P, а объем оперативной памяти системы составлял 32GB с использованием модулей Kingston DDR4 DIMM.

Для оценки качества работы алгоритмов распознавания объектов использована метрика mAP (mean average precision), включенная в библиотеку YOLOv7 для Python [19]. Метрика mAP учитывает не только точность (precision) обнаружения объектов (листьев земляники садовой с признаками недостатка кальция), но и полноту (recall) алгоритма. Она представляет собой среднее значение точности для разных значений порога (threshold) нахождения объектов:

$$mAP = \frac{(AP_1 + AP_2 + \dots + AP_n)}{n}, \quad (2)$$

где n – количество классов объектов, которые должны быть обнаружены алгоритмом, шт., AP_1, AP_2, \dots, AP_n – average precision (средняя точность) для каждого класса.

Метрика Precision – доля правильно определенных положительных объектов относительно всех объектов, которые классификатор определил как положительные, получена:

$$Precision = \frac{TP}{TP + FP}. \quad (3)$$

Метрика Recall – доля правильно определенных положительных объектов относительно всех положительных объектов в данных, найдена по формуле:

$$Recall = \frac{TP}{TP + FN}, \quad (4)$$

где TP (True Positive) – количество правильно определенных объектов как положительные; FP (False Positive) – количество неправильно определенных объектов как положительные; FN (False Negative) – количество неправильно определенных объектов как отрицательные.

Мера точности и полноты классификационной модели определена с помощью метрики F1-score (F-мера), которая представляет собой гармоническое среднее между точностью (precision) и полнотой (recall) модели, используется для оценки качества бинарной классификации, находится по формуле:

$$F1\text{-score} = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}. \quad (5)$$

Для оценки вероятности того, что модель правильно определила область поражения на листьях земляники садовой на изображении использован показатель Confidence (доверительность). В модели YOLOv7 Confidence представлен как значение вероятности присутствия объекта классификации в bounding box (в прямоугольнике), а также вероятности правильной классификации этого объекта. Показатель Confidence определяли по формуле:

$$Confidence = Pr(object) \cdot IoU(bbox, object), \quad (6)$$

где $Pr(object)$ – вероятность наличия объекта в рамке (bounding box), $IoU(bounding\ box, object)$ – значение Intersection over Union (IoU) между рамкой и реальным объектом в ней.

Для расчета mAP использована кривая precision-recall, которая строится на основе результатов алгоритма обнаружения объектов. После построения кривой precision-recall вычисляется площадь под ней (average precision, AP).

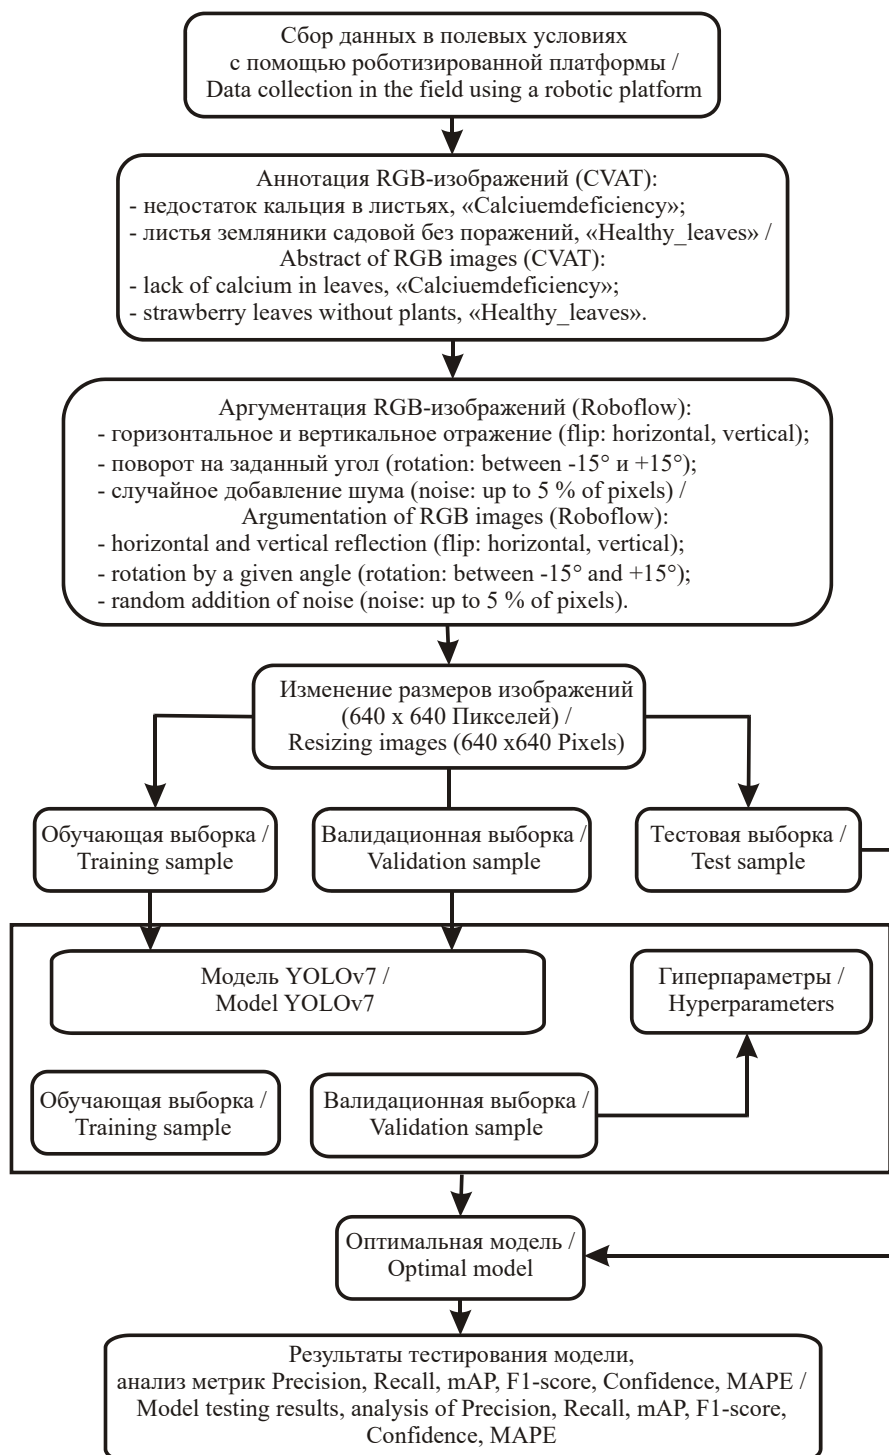


Рис. 4. Алгоритм применения сверточной нейронной сети для мониторинга состояния листьев земляники садовой /

Fig. 4. Algorithm of application of convolutional neural network for monitoring the condition of strawberries

Для оценки точности прогноза идентификации листьев земляники садовой с недостатком кальция проводили расчет средней абсолютной ошибки (Mean Absolute Percentage Error, MAPE) анализируемой модели нейронной сети YOLOv7, используя формулу:

$$MAPE = \frac{1}{n} \sum_{i=1}^K \left| \frac{\Phi_i - \Pi_i}{\Phi_i} \right|, \quad (7)$$

где Φ_i — фактическое количество изображений класса Calciuemdeficiency на тестовой выборке, шт. (классифицированных визуальным методом экспертами-агрономами);

Π_i — количество изображений класса Calciuemdeficiency, верно идентифицированных с помощью модели нейронной сети, шт.

Использование метрик обосновано многолетними исследованиями по применению методов и алгоритмов машинного обучения известными учеными [18, 19], расчеты проведены в соответствии с ГОСТ Р 70462.1-2022².

Результаты и их обсуждение. В результате проведенных исследований разработан алгоритм применения сверточной нейронной сети YOLOv7 для мониторинга состояния листьев земляники садовой (рис. 4).

Алгоритм включает в себя операции по сбору набора данных в полевых условиях, аннотацию полученного набора данных

(изображений), аргументацию изображений, обучение и тестирование сверточной нейронной сети YOLOv7.

Проведено трансферное обучение модели YOLOv7 на 4000 шт. изображений обучающего набора данных. Тестовый набор данных с пораженными листьями земляники садовой и без поражения в количестве 400 шт. использован для анализа качества работы модели. Примеры распознавания поражений листьев земляники садовой на изображениях с помощью обученной модели с выделением областей поражения в рамку представлены на рисунке 5.



Рис. 5. Примеры распознавания поражений листьев земляники садовой на изображениях с помощью обученной модели YOLOv7 /

Fig. 5. Examples of recognition of strawberry leaf damage in images using a trained YOLOv7 model

Для оценки полученных значений точности и полноты при изменении порога для принятия решения в задаче бинарной классификации построена кривая Precision-Recall (точность-полнота) (рис. 6). Анализ графика Precision-Recall позволил установить порог классификации 0,39, который обеспечивает наилучшее соотношение между точностью и полнотой.

Для оценки качества работы нейронной сети построены кривые Precision-Confidence и Recall-Confidence, которые отражают зависи-

мость точности и полноты предсказаний модели от уровня доверительности, используемого для принятия решения о наличии объекта на изображении (рис. 7). Анализ кривых позволил оценить оптимальный уровень доверительности для модели, который составил 0,57. Показатель обеспечивает оптимальную точность и полноту предсказаний класса Calcium deficiency поражения листьев земляники садовой при минимальном количестве ложных срабатываний модели нейронной сети.

²ГОСТ Р 70462.1-2022. Информационные технологии. Интеллект искусственный. Оценка робастности нейронных сетей. Ч.1. Обзор. М.: Российский институт стандартизации, 2022. 32 с. URL: <https://files.stroyinf.ru/Data/790/79058.pdf>




Рис. 6. Кривая оценки точности и полноты
Precision-Recall /
Fig. 6. Precision-Recall Curve





Рис. 7. Кривые оценки качества работы нейронной сети: а – кривая Precision-Confidence, б – кривая Recall-Confidence /

Fig. 7. Neural network quality assessment curves: а – Precision-Confidence curve, б – Recall-Confidence curve

Полученный F1-Confidence график позволил оценить, как изменение уровня уверенности модели влияет на объединенные метрики точности и полноты, способность правильно классифицировать объекты и выбрать оптимальный порог для принятия решения о классификации, который составил 0,54 (рис. 8). F1-Confidence график показывает, как модель реагирует на различные уровни шума или наличие выбросов в данных. Например, если на графике наблюдается резкий спад F1-меры при увеличении уровня уверенности модели, то это может свидетельствовать о том, что модель слишком чувствительна к шуму или выбросам в данных, и необходимо провести дополнительную обработку данных или внести изменения в алгоритм обучения модели.




Рис. 8. Кривая оценки качества работы нейронной сети F1-Confidence на объединенные метрики точности (precision) и полноты (recall) /

Fig. 8. The curve for evaluating the quality of the F1-Confidence neural network on the combined metrics of precision and recall

Для анализа изменений значения функции потерь модели в процессе обучения в зависимости от количества эпох построен график Objectness-Epoch (рис. 9, а). График позволил оценить оптимальное количество эпох, необходимых для достижения максимального качества обнаружения объектов и исключения переобучения модели, которое составило 89. Полученный Вох-Epoch график отображает изменение метрики mAP, которая оценивает качество определения координат ограничивающих рамок объектов на каждой эпохе обучения модели (рис. 9, б). Вох-Epoch график позволил определить оптимальное количество эпох обучения, при котором достигается наилучшее качество определения координат ограничивающих рамок объектов, которое составило 83. Для оценки изменения показателей точности и полноты в зависимости от эпохи в процессе обучения модели построены кривые Precision-Epoch и Recall-Epoch (рис. 9, в, г) Для оценки изменения средней точности модели в зависимости от количества эпох в процессе обучения модели построена кривая mAP-Epoch (рис. 9, д). Анализ кривых Precision-Epoch, Recall-Epoch, mAP-Epoch позволил определить количество эпох, когда модель достигает наилучшего

сочетания точности и полноты и выбрать наилучшие гиперпараметры для достижения наилучшей производительности модели и максимальной точности детектирования класса «Calciumdeficiency», выделения областей на листьях земляники с недостатком кальция, которое составило 52. Общее время обучения модели YOLOv7 при использовании CPU составило 9 час 9 минут 8 секунд.

Анализ полученных графиков (рис. 9, а-д) позволил установить оптимальные параметры настройки нейронной сети YOLOv7, выбрать порог уверенности, на котором модель показывает оптимальную точность и полноту, сбалансированную с количеством обнаруженных объектов. Определена конфигурация алгоритма машинного обучения модели YOLOv7 для распознавания областей поражения листьев земляники садовой с признаками недостатка кальция, класс «Calciumdeficiency»: скорость обучения (learning rate) – 0,01 LR (learning rate), количество эпох (epochs) – 78, размер мини-пакета (batch size) – 16.

Результаты расчетов средней абсолютной ошибки модели нейронной сети YOLOv7 представлены в таблице.

Таблица – Средняя абсолютная ошибка модели нейронной сети YOLOv7 / Table – Average absolute error of the YOLOv7 neural network model

Классификатор / Вид поражения / Classifier / Type of damage	Количество изображений, шт. / Number of images, pcs		Средняя абсолютная ошибка, % / Mean Absolute Percentage Error (MAPE), %
	тестовой выборки / number of test sample images	верно классифицированных с помощью модели YOLOv7 / correctly classified using the YOLOv7 model	
«Calciumdeficiency» / Недостаток кальция в листьях земляники садовой / «Calciumdeficiency» / Lack of calcium in strawberry leaves	200	186	7,52
«Healthy_leaves» / Листья земляники садовой без поражений / «Healthy_leaves» / Strawberry leaves without damage	200	193	3,62
Всего / Total	400	379	5,57

Анализ полученных результатов показал, что модель YOLOv7 классифицировала класс «Calciumdeficiency» с показателем MAPE, равным 7,52 %. Среднее абсолютное отклонение результатов распознавания модели YOLOv7 изображений листьев с признаками недостатка кальция и здоровых листьев от визуально идентифицированных экспертами-агрономами не превысила 5,57 %. Расчетное значение метрики бинарной классификации mAP составило 0,454, метрики F1-score – 0,53.

Результаты исследований показали, что своевременный мониторинг состояния земляники садовой на промышленной плантации, проведенный с использованием колесной роботизированной платформы с применением свёрточной нейронной сети YOLOv7 для обработки полученных данных, позволит на ранних этапах развития патологии с точностью до 94,43 % определить дефицит кальция в листьях растений земляники садовой.




Рис. 9. Графики оценки качества работы нейронной сети YOLOv7: а – кривая Objectness-Epoch оценки функции потерь модели, б – кривая Box-Epoch оценки изменения метрики mAP, в – кривая Precision-Epoch, г – кривая Recall-Epoch, д – кривая mAP-Epoch оценки изменения метрики mAP /

Fig. 9. Graphs for evaluating the quality of the YOLOv7 neural network: а – the Objectness-Epoch curve for estimating the loss function of the model, б – the Box-Epoch curve for estimating changes in the mAP metric, в – the Precision-Epoch curve, г – the Recall-Epoch curve, д – the mAP-Epoch curve for estimating changes in the mAP metric

Заключение. В исследованиях применен метод обучения нейронной сети в условиях ограниченного объема обучающей выборки, полученной в полевых условиях с помощью роботизированной платформы с RGB-камерой. Результат показал, что искусственное увеличение объема обучающей выборки (изображений листьев земляники садовой), использование таких инструментов, как горизонтальное и вертикальное отражение, поворот на заданный угол и случайное добавление шума позволяет существенно повысить качество обучения нейронной сети, помогает адаптировать систему к реальным условиям, повышает точность

обнаружения признаков дефицита кальция в растениях на 18 % по сравнению с набором данных без увеличения объема выборки.

Обученная в рамках проведенных исследований методом трансферного обучения модель сверточной нейронной сети предназначена для распознавания одного класса – «Calciumdeficiency» (листья земляники с недостатком кальция). Исследования показали перспективы применения сверточной нейронной сети в составе системы поддержки принятия решений, в том числе для определения других видов поражений листьев земляники садовой и других сельскохозяйственных культур.

References

1. Dunn J. L., Able A. J. Pre-harvest calcium effects on sensory quality and calcium mobility in strawberry fruit. *Acta Horticulture*. 2006;708(708):307-312. DOI: <https://doi.org/10.17660/ActaHortic.2006.708.52>
2. Moore K. A., Bradley L. K. North Carolina extension gardener handbook (Ch. 5). The University of North Carolina Press, North Carolina, USA, 2018. URL: <https://content.ces.ncsu.edu/extension-gardener-handbook/5-diseases-and-disorders>
3. Kuronuma T., Watanabe Y., Ando M., Watanabe H. Tipburn severity and calcium distribution in lisianthus (*Eustoma grandiflorum* (Raf.) Shinn.) cultivars under different relative air humidity conditions. *Agronomy*. 2018;8(10):218. DOI: <https://doi.org/10.3390/agronomy8100218>
4. Bárcena A., Graciano C., Luca T., Guiamet J. J., Costa L. Shade cloths and polyethylene covers have opposite effects on tipburn development in greenhouse grown lettuce. *Scientia Horticulturae*. 2019;249:93-99. DOI: <https://doi.org/10.1016/j.scienta.2019.01.023>
5. Olle M., Williams I. H. Physiological disorders in tomato and some methods to avoid them. *The Journal of Horticultural Science and Biotechnology*. 2017;92(3):223-230. DOI: <https://doi.org/10.1080/14620316.2016.1255569>
6. Saygi H. Effects of Organic Fertilizer Application on Strawberry (*Fragaria vesca* L.) Cultivation. *Agronomy*. 2022;12(5):1233. DOI: <https://doi.org/10.3390/agronomy12051233>
7. Mohamed M. H. M., Petropoulos S. A., Ali M. M. E. The Application of Nitrogen Fertilization and Foliar Spraying with Calcium and Boron Affects Growth Aspects, Chemical Composition, Productivity and Fruit Quality of Strawberry Plants. *Horticulturae*. 2021;7(8):257. DOI: <https://doi.org/10.3390/horticulturae7080257>
8. Cvelbar Weber N., Koron D., Jakopič J., Veberič R., Hudina M., Baša Česnik H. Influence of Nitrogen, Calcium and Nano-Fertilizer on Strawberry (*Fragaria × ananassa* Duch.) Fruit Inner and Outer Quality. *Agronomy*. 2021;11(5):997. DOI: <https://doi.org/10.3390/agronomy11050997>
9. Sabatino L., D'Anna F., Prinzivalli C., Iapichino G. Soil Solarization and Calcium Cyanamide Affect Plant Vigor, Yield, Nutritional Traits, and Nutraceutical Compounds of Strawberry Grown in a Protected Cultivation System. *Agronomy*. 2019;9(9):513. DOI: <https://doi.org/10.3390/agronomy9090513>
10. Kim H. M., Lee H. R., Kang J. H., Hwang S. J. Prohexadione-Calcium Application during Vegetative Growth Affects Growth of Mother Plants, Runners, and Runner Plants of Machyang Strawberry. *Agronomy*. 2019;9(3):155. DOI: <https://doi.org/10.3390/agronomy9030155>
11. Cruz M., Mafra S., Teixeira E., Figueiredo F. Smart Strawberry Farming Using Edge Computing and IoT. *Sensors*. 2022;22(15):5866. DOI: <https://doi.org/10.3390/s22155866>
12. Basak J. K., Paudel B., Kim N. E., Deb N. C., Kaushalya Madhavi B. G., Kim H. T. Non-Destructive Estimation of Fruit Weight of Strawberry Using Machine Learning Models. *Agronomy*. 2022; 12(10):2487. DOI: <https://doi.org/10.3390/agronomy12102487>
13. Ferentinos K. P. Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*. 2018;145:311-318. DOI: <https://doi.org/10.1016/j.compag.2018.01.009>
14. Vieira G. S., Fonseca A. U., Rocha B. M., Sousa N. M., Ferreira J. C., Felix J. P., Lima J. C., Soares F. Insect Predation Estimate Using Binary Leaf Models and Image-Matching Shapes. *Agronomy*. 2022;12(11):2769. DOI: <https://doi.org/10.3390/agronomy12112769>
15. 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 Sensing*. 2021;13(3):531. DOI: <https://doi.org/10.3390/rs13030531>
16. Mahmud M. S., Zaman Q. U., Esau T. J., Chang Y. K., Price G. W., Prithiviraj B. Real-Time Detection of Strawberry Powdery Mildew Disease Using a Mobile Machine Vision System. *Agronomy*. 2020;10(7):1027. DOI: <https://doi.org/10.3390/agronomy10071027>
17. Khort D., Kutyrev 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;1158:334-343. DOI: https://doi.org/10.1007/978-3-030-61656-4_22
18. Maxwell A. E., Warner T. A., Guillén L. A. Accuracy Assessment in Convolutional Neural NetworkBased Deep Learning Remote Sensing Studies - Part 1: Literature Review. *Remote Sensing*. 2021;13(13):2450. DOI: <https://doi.org/10.3390/rs13132450>
19. 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;13(13):2591. DOI: <https://doi.org/10.3390/rs13132591>

Сведения об авторах

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

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

Information about the authors

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

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

✉ – Для контактов / Corresponding author