

Нейронная сеть для распознавания и классификации плодов яблони

Алексей Игоревич Кутырёв, Игорь Геннадьевич Смирнов

Федеральный научный агроинженерный центр ВИМ, г. Москва, Россия.

e-mail: alexeykutirev@gmail.com

Аннотация. В статье предлагается метод мониторинга промышленных садов на основе искусственного интеллекта и машинного обучения. Для идентификации плодов яблони на кроне дерева с помощью движущейся в рядах садовых насаждений роботизированной платформы с закрепленной на ней камерой разработана нейронная сеть, использована модель VGG-16 и архитектура SSD, которые детектируют выходное пространство и генерируют ограничивающие прямоугольники на изображениях с различными соотношениями сторон. Для подсчета количества плодов относительно каждого ряда насаждений, предлагается метод сшивания серии фотографий плодовых деревьев в ряду в цилиндрическую панораму. Для оценки качества разработанной нейронной сети при работе с 6 классами применена задача мульти-классификации. Анализ результатов проведенных исследований показал, что разработанная модель нейронной сети обладает высокой производительностью и высоким качеством упорядочивания объектов классов. Разработанная нейронная сеть позволяет вести обработку не менее 200 запросов, идентифицировать на изображениях кроны деревьев здоровые плоды яблони и плоды яблони, пораженные болезнями, вести подсчет их количества.

Ключевые слова: цифровой мониторинг; идентификация плодов яблони; нейронная сеть; обработка изображений; точное садоводство; прогнозирование.

Для цитирования: Кутырёв А. И., Смирнов И. Г. Нейронная сеть для распознавания и классификации плодов яблони // Аграрный научный журнал. 2023. № 8. С. 123–133. <http://dx.doi.org/10.28983/asj.y2023i8pp123-133>.

AGRICULTURAL ENGINEERING

Original article

Neural network for apple fruit recognition and classification

Alexey I. Kutirev, Igor G. Smirnov

Federal State Budgetary Scientific Institution «Federal Scientific Agroengineering Center VIM», Moscow, Russia

e-mail: alexeykutirev@gmail.com

Abstract. The article proposes a method for monitoring industrial gardens based on artificial intelligence and machine learning. To identify apple fruits on the crown of a tree using a robotic platform moving in the garden areas with a camera attached to it, a neural network was developed, the VGG-16 model and SSD architecture were used, which detect the output space and generate bounding rectangles in images with different aspect ratios. To count the number of fruits relative to each row of plantings, a method is proposed for stitching a series of photographs of fruit trees in a row into a cylindrical panorama. To assess the quality of the developed neural network when working with 6 classes, the multi-classification task was applied. Analysis of the results of the conducted research has shown that the developed neural network model has high performance and high quality of ordering class objects. The developed neural network allows processing at least 200 requests, identifying healthy apple fruits and apple fruits affected by diseases on tree crown images, and counting their number.

Keywords: digital monitoring, apple fruit identification, neural network, image processing, precision horticulture, prediction.

For citation: Kutirev A. I., Smirnov I. G. Research on the work of ameliorative pumping stations of the Volga branch of FSBI “Management “Saratovmeliovodkhoz” and ways to improve them // Agrarnyy nauchnyy zhurnal = The Agrarian Scientific Journal. 2023;(8):123–133. (In Russ.). <http://dx.doi.org/10.28983/asj.y2023i8pp123-133>.





Введение. Несовершенство традиционных сельскохозяйственных технологий не позволяет адресно и превентивно реагировать на угрозы промышленным садовым насаждениям. В отличие от полевых культур, для которых возможен мониторинг «по площадям», эффективное наблюдение за плодовыми растениями должно осуществляться на уровне индивидуальных растений (саженцев, деревьев) и их органов (соцветий, плодов и листьев). Большинство современных технологий мониторинга не обеспечивают необходимого для этого пространственного разрешения [1]. Для решения этой проблемы нужны более совершенные подходы к получению изображений растительных объектов и обработки этих изображений.

Комплекс инновационных подходов и технологий, известных как «точное садоводство» (precision horticulture), позволит отслеживать состояние промышленных садов в реальном времени с высокой точностью на уровне отдельных растений и плодов [2]. Для дистанционного мониторинга садовых насаждений и прогноза их потенциальной урожайности необходимо собирать, хранить и обрабатывать большой объем данных. Для получения данных возможно применение аппаратных средств с RGB камерами, с помощью которых возможен периодический учет формирования урожайности в различные фазы развития растений в течение вегетационного периода [3–5]. Такие снимки позволяют проводить контроль наступления ключевых фаз развития садовых растений: распускание листьев, цветение, завязывание и вызревание плодов с учётом влияния внешних факторов, а также диагностировать поражение растений болезнями.

Анализ исследований известных ученых показал, что применение архитектуры искусственных нейронных сетей обеспечит качественное обнаружение объектов, позволит классифицировать объекты с высокой степенью точности, путем прямого ввода, полученного изображений в модель [6, 7]. Имитация зрительных возможностей человека, использование цифровой обработки изображений в режиме реального времени, полученных в полевых условиях, является фундаментальным шагом на пути к автоматизации процесса идентификации плодов, точного подсчета их количества и диагностики болезней [8,9].

Цель исследования – создание метода мониторинга промышленных садов на основе искусственного интеллекта и машинного обучения, обеспечивающего повышение продуктивности садоводства, рациональное применение средств защиты растений и удобрений, а также предпосылки для более полного сохранения плодовой продукции и повышения качества плодов яблони.

Методика исследований. В результате проведенных исследований для идентификации плодов яблони на кроне дерева с помощью движущейся в рядах садовых насаждений роботизированной платформы с закрепленной на ней камеры разработана нейронная сеть. Основная задача нейронной сети – идентификация и сегментация на входящих изображениях кроны деревьев здоровых плодов яблони и плодов яблони, пораженных болезнями и подсчет их количества.

Для разработки нейронной сети использована модель VGG-16 (Very Deep Convolutional Networks) и архитектура SSD (Single Shot MultiBox Detector), которые детектирует выходное пространство и генерируют ограничивающие прямоугольники с различными соотношениями сторон. Таким образом нейронная сеть классифицирует за один проход объекты (плоды яблони) и на одном кадре, ведет подсчет разных типов объектов и учитывает их нахождение в определенной зоне. Нейронная сеть имеет возможность прогнозирования и определения баллов присутствия каждой категории объектов в каждом ограничивающем прямоугольнике и вносит коррективы в поле, чтобы точнее соответствовать форме объекта.

Отличительной особенностью выбранной архитектуры SSD является возможность распознавания объектов за один прогон с помощью заданной сетки окон (default box) на пирамиде изображений. Скорость обработки изображений может достигать до 59 FPS (Frames Per Second, кадров в секунду). Для работы нейронной сети использован следующий список библиотек Python: tensorflow-gpu, Numpy, OpenCV. Библиотеки Nvidia: CUDA, CUDA toolkit, CuDNN. Библиотеки драйверов: Driver Nvidia Version: 515.65.01, CUDA Version: 11.7.

В результате проведенных исследований определены входные данные необходимые для выполнения заданных функций нейронной сети и выходная информация, получаемая в результате выполнения нейронной сетью своих функций. Входные данные включают в себя изображение объекта исследования в формате PNG или JPEG, значения расстояния до объекта исследования (измеренное цифровой камерой, либо введенное вручную оператором), географические координаты места получения изображения (широта, долгота, высота над уровнем моря), информация,



характеризирующая оптическую систему с помощью, которой получается изображение (реальный и мнимый размер матрицы камеры, фокусное и эквивалентное фокусное расстояние, разрешение изображения объекта, вертикальное и горизонтальное, цифровое увеличение), информация, персонализирующая объект исследования (сезон, поле, сорт, фаза вегетации).

Выходная информация включает в себя результат исследования объекта на принадлежность к плоду яблони – да/нет, результат подсчета количества идентифицированных здоровых плодов и плодов, пораженных болезнями (объем урожая в расчете на гектар), результат исследования объекта (выделение области занимаемой объектом на изображении, файл изображения-маски в формате PNG), площадь области занимаемой объектом на изображении, рассчитанная по характеристикам оптической системы, расстоянию до объекта и изображению-маск, журнал с систематизированной информацией о полученных данных, персонализирующих объект исследования с сохранением файлов изображения и маски объекта исследования на файловой системе сервера в базе данных с возможностью просмотра истории результатов исследования объекта.

Сбор данных (dataset) для обучения нейронной сети проведен на промышленной плантации яблоневого сада возрастом 7 лет в научно-производственном отделе испытаний ФГБНУ ФНЦ Садоводства (Московская обл., Ленинский район, поселок Булатниково). Сбор данных осуществлен непосредственно с роботизированной платформы движущейся в рядах насаждений с закрепленной на ней камеры, а также путем фотографирования кроны плодовых деревьев с разных ракурсов с помощью камеры Sony Alpha ILCE-7M3 с объективом Sony FE 24-240mm f/3.5-6.3 OSS (SEL24240), с последующей нормализацией изображений под требования нейронной сети с учетом требований постобработки к разрешению входных изображений.

Для обучения нейронной сети использован метод разделения полученного набора данных (выборки) на 3 части – обучающий, валидационный и тестовый. Модель нейронной сети оценивается по качеству на валидационной выборке, а по завершении разработки проходит финальную апробацию на тестовых данных, не использованных в процессе обучения. Количество данных для обучения нейронной сети составило: 8000 изображений (фото плодов яблони на кроне деревьев) – обучающий набор, 4000 изображений – валидационный набор, 600 изображений – тестовый набор: 300 изображений – одно плодовое дерево в кадре и 300 изображений – несколько плодовых деревьев в кадре.

Разметка данных для обучения нейронной сети проведена в онлайн сервисе VGG Image Annotator, для аннотирования использованы прямоугольники. Размеченный файл аннотации формата .json включает в себя координаты всех прямоугольников. В результате выделено 2 класса здоровых яблок – красное, зеленое (Red, Green), 3 класса яблок, пораженных болезнями – парша, мучнистая роса, гниль плодовая (Scab, Powdery, Rot) и 1 класс яблок с механическим повреждением (Mehan) сортов Президент, Останкино, Валюта, Червонец, Лукомор, Малюха. Сенатор, Триумф (табл. 1).

Технические характеристики компьютера, используемого для обучения нейронной сети: процессор CPU Intel Socket 2066 Core i9-10900X 3.70GHz, видеокарта GeForce RTX 2080TI 11GB, материнская плата GIGABYTE X299 UD4 Pro, накопитель SSD Intel PCI-E 1Tb 660P, модуль памяти Kingston DDR4 DIMM 32GB.

По результатам работы нейронная сеть глубокого обучения проводит оценку количества плодов на деревьях на исследуемом ряде насаждений, имеет возможность фиксирования географических координат измерений, хранит результаты расчетов нейронной сети, содержащихся в базе данных.

В настоящее время для оценки работы нейронных сетей при идентификации объектов используются различные метрики [10]. Для оценки качества разработанной нейронной сети при работе с 6 классами применена задача мульти-классификации. Использованы такие метрики как Precision (точность), Recall (полнота), True Positive Rate (TPR, доля верно классифицированных положительных примеров), True negative rate (TNR, доля верно классифицированных отрицательных примеров), False negative rate (FNR, количество неверно классифицированных отрицательных примеров), False positive rate (FPR, доля неверно классифицированных положительных примеров), Accuracy (общая точность предсказания модели по всем классам), F-score (F-мера, среднее гармоническое precision и recall), Specificity (специфичность), Overall accuracy (OA, доля верно классифицированных примеров от общего количества примеров), Balanced Accuracy (BA, взвешенную точность).

Матрица ошибок (матрица неточностей)

Ответы	0	TP (Верно-положительные)	FN (Верно-отрицательные, ошибка II рода)
	1	FP (Ложно-положительные, ошибка I рода)	TN (Ложно-отрицательный)
		0	1
		Предсказания	

Построена матрица ошибок (матрица неточностей), в которой по горизонтали расположены «предсказания» метрики алгоритма по вертикале «ответы» истинные метки класса (см. табл. 1).

Матрица на вход принимает верные ответы и предсказания, а возвращает матрицу ошибок. Использована оценка средней метрики (Average) по всем классам. В качестве «положительного» класса берется вычисляемый класс, а все остальные классы в качестве «отрицательного». В этом случае формула для метрики Accuracy, измерения количества верно классифицированных объектов относительно общего количества всех объектов, принимает соединяющий вид, формула (1):

$$\text{Average Accuracy} = \frac{\sum_{i=1}^K \frac{TP+TN}{TP+TN+FP+FN}_i}{K}; \quad (1)$$

где K – количество классов, шт.

Метрика Average Precision, предсказания положительных классов, найдена по формуле (2):

$$\text{Average Precision} = \frac{\sum_{i=1}^K \frac{TP}{TP+FP}_i}{K}; \quad (2)$$

Метрика Average Precision определяет, как много отрицательных ответов нашла модель, пока искала положительные. Чем больше отрицательных, тем ниже точность полученного результата.

Метрика Average Recall предсказания отрицательных классов, найдена по формуле (3):

$$\text{Average Recall} = \frac{\sum_{i=1}^K \frac{TP}{TP+FN}_i}{K}; \quad (3)$$

Метрика Average Recall выявляет какую долю положительных среди всех ответов выделила модель.

Для параллельного контроля метрик полноты и точности использована метрика F-score для определения среднего гармонического, найденная по формуле (4):

$$\text{Average F – score} = \frac{\sum_{i=1}^K (2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}})_i}{K}; \quad (4)$$

Метрика AUC-ROC, оценки качества упорядочивания алгоритмом объектов шести классов, найдена по формуле (5):

$$\text{AUC – ROC}_{\text{Total}} = \sum_{i=1}^K \text{AUC – ROC}(c_i) \cdot f(c_i); \quad (5)$$

где $f(c)$ – относительная частота класса.

Метрика Specificity использована для расчета вероятности правильного распознавания для отрицательных наблюдений (отношение верных срабатываний классификатора к общему числу объектов за пределами класса), найдена по формуле (6):

$$\text{Average Specificity} = \frac{\sum_{i=1}^K \frac{TN}{TN+FP}_i}{K}; \quad (6)$$

Метрика Specificity стремится к 0 если количество ложно-положительных классификаций велико. Если число ложно-положительных наблюдений стремится к 0, то метрика Specificity стремится к 1 и обеспечивает большую вероятность правильного распознавания объектов для отрицательных наблюдений.



Метрика Overall accuracy (OA) использована для расчета доли правильных ответов на всех классах, найдена по формуле (7):

$$\text{Average OA} = \frac{\sum_{i=1}^K \left(\frac{TP+TN}{TP+TN+FP+FN} \right)_i}{K}; \quad (7)$$

Для избегания завышенных оценок производительности на несбалансированных данных вычислена метрика Average Balanced Accuracy (BA) по формуле

$$\text{Average BA} = \frac{\sum_{i=1}^K BA_i}{K}; \quad (8)$$

Для измерения насколько классификатор находит объекты (плоды яблони), определения долей верно предсказанных объектов к общему числу объектов класса использована метрика Average True Positive Rate (TPR), найденная по формуле

$$\text{Average TPR} = \frac{\sum_{i=1}^K \left(\frac{TP}{TP+FN} \right)_i}{K}; \quad (9)$$

Доля неверно классифицированных положительных примеров от общего количества отрицательных примеров, метрика Average False positive rate (FPR) определена по формуле

$$\text{Average FPR} = \frac{\sum_{i=1}^K \left(\frac{FP}{FP+TN} \right)_i}{K}; \quad (10)$$

Для подсчета количества плодов относительно каждого ряда насаждений предлагается метод сшивания серии фотографий плодовых деревьев в ряду в цилиндрическую панораму. Длинные (гигапиксельные) кадры рядов насаждений, вытянутые по горизонтали, позволяют исключить дублирование подсчета яблок с помощью разработанной нейронной сети, обеспечивают захват всей рабочей области.

При съемке рядов садовых насаждений с помощью камеры, закрепленной на роботизированной платформе, движущейся с постоянной скоростью, изменение геометрии поверхности грунтов оказывает существенное влияние на изменение («заваливание») горизонта полученной панорамы, вследствие чего возникают локальные артефакты и рассогласование текстур. При захвате изображений с RGB камеры искажения на панорамных снимках возникают вследствие горизонтального и вертикального смещения камер (рис. 1).

Для получения высокодетализированных изображений при перемещении камеры необходимо, чтобы отношение перекрывающей области к ширине изображения было минимальным. На основании параметров съемки, качества и масштаба получаемой панорамы, по формуле (1) подбирается необходимое расстояние до ряда яблоневых деревьев:

$$S = \frac{f}{H_g}; \quad (11)$$

где f – откалиброванное фокусное расстояние камеры, мм, H_g – расстояние от кроны деревьев до роботизированной платформы, мм.

При поступательном движении величину перекрытия кадров (отношение ширины перекрывающей области I , мм к ширине изображения L , мм) можно определить по формуле (2):

$$\frac{I}{L} = 1 - \frac{t}{2d \cdot \text{tg}\left(\frac{\gamma}{2}\right)}; \quad (12)$$

В случае вращения камеры величина перекрытия кадров находится по формуле (3):

$$\frac{I}{L} = \frac{\frac{L}{2} \left[1 - \frac{\text{tg}\left(\alpha - \frac{\gamma}{2}\right)}{\text{tg}\frac{\gamma}{2}} \right]}{L}; \quad (13)$$






Рис. 1. Схема получения и обработки фото при мониторинге рядов насаждений с западной и восточной сторон

Для оценки качества работы предлагаемого метода проведен лабораторный эксперимент по созданию и обработке с помощью разработанной нейронной сети панорамного снимка. Для получения панорамного снимка использована роботизированная платформа с закрепленной на ней цифровой камерой (рис. 2).




Рис. 2. Проведение лабораторного эксперимента по созданию и обработке с помощью нейронной сети панорамного снимка

При движении роботизированной платформы с постоянной скоростью 1 км/ч получены снимки ряда искусственных моделей яблоневых деревьев. Сшивание полученных кадров ряда в панораму проведено в программной среде PTGui. Генерация контрольных точек в серии полученных фотографий искусственного ряда яблоневых деревьев позволило автоматически сшить фотографии между соседними сценами. Для определения зон перекрытия кадров для сшивания, в программной среде указано фокусное расстояние и кроп-фактор матрицы.

Результаты исследований. Расчет метрик оценки качества работы разработанной нейронной сети проведен на тестовом наборе изображений, для анализа качества работы нейронной сети использовано 600 фотографий яблоневых деревьев (рис. 3).



Рис. 3. Анализ изображений разработанной нейронной сетью

Результаты обработки полученных данных, расчетные значения метрик мульти-классификации представлены в табл. 2.

Таблица 2

Результаты расчетов метрик мульти-классификации

Метрика	Значение
Average Precision	0,926
Average Recall	0,961
Average Accuracy	0,917
Average F-score	0,946
Average Specificity	0,083
Average Overall accuracy	0,915
Average Balanced Accuracy	0,520
AUC-ROC _{Total}	0,911

Для анализа полученных результатов работы нейронной сети построена PR-кривая, на которой по оси абсцисс задаются значения Precision, по оси ординат значения Recall при изменении порогового значения. Полученная PR-кривая при использовании шести классов представлена на рис. 4, а. Значение площади под Precision-Recall кривой при использовании шести классов составило 0,8241. Для оценки определения ошибок построена ROC-кривая, на которой по оси абсцисс задаются значения доли False positive rate (FPR), а по оси ординат доля истинно положительных ответов True Positive Rate (TPR) (рис. 4, б). Для выявления насколько разработанная модель отличается от случайной проведен расчет площади под ROC-кривой (AUC-ROC метрика). AUC-ROC это метрика качества, определяется от 0 до 1. AUC-ROC случайной модели равна 0,5. Анализ полученного графика показал, что значение площади под ROC-кривой AUC составляет 0,9115. Анализ показал что разработанная модель нейронной сети обладает высокой производительностью и высоким качеством упорядочивания объектов классов. Площадь под ROC кривой и PR кривой находится в диапазоне $0,5 < \text{AUC/PR} < 1$, что говорит о высокой вероятности, что классификатор сможет точно различить положительные и отрицательные значения класса. Среднее гармоническое между Precision и Recall метриками составило Average F-score = 0,946, что показывает высокую степень поиска релевантных результатов.

Установлено оптимальное количество эпох для обучения нейронной сети при работе с тестовыми данными. Обучение на наборе данных остановлено на 5-й эпохе (рис. 4, в). Начиная с 5 эпохи обучения потери данных модели уменьшаются, не превышают 0,071 (рис. 4, г).






Рис. 4. Результаты обработки полученных данных, расчетные значения метрик мульти-классификации: а – кривая Precision-Recall; б – ROC-кривая; в – график зависимости точности от эпохи обучения нейронной сети; г – график зависимости ошибок от эпохи обучения нейронной сети

Программное средство PTGui позволило автоматически оптимизировать снимки, установить вертикаль изображений и дистанцию между контрольными точками при сшивке фотографий не более 15 пикселей (рис. 5).




Рис. 5. Результаты идентификации плодов на сшитом изображении в программной среде PTGui

На сшитом панорамном снимке разработанная нейронная сеть идентифицировала все видимые искусственные модели плодов яблони со средней вероятностью того, что плод принадлежит классу «Red» не менее 85,2 % при расстоянии от камеры до ряда яблоневых деревьев не более 3 м и величине перекрытия полученных кадров не более 15 пикселей.

В результате проведенных исследований разработан алгоритм обработки панорамных снимков предлагаемым методом при мониторинге рядов насаждений с западной и восточной стороны ряда с помощью роботизированной платформы (рис. 6).

Низкоуровневая обработка включает в себя получение изображения от RGB камер и перевод их в цифровую форму, предварительную обработку, которая приводит изображения к единому формату, убирая шумы, искажения и корректируя цветовые уровни, а также сшивание полученных изображений в цилиндрическую панораму.

Промежуточная обработка включает в себя выделение объекта на изображении. Сегментация и выделение объектов может быть осуществлена 3 разными способами: пороговая сегментация, сегментация на основе краев и сегментация на основе областей. Результатом промежуточной обработки является выделение плода на изображении.

Высокоуровневая обработка включает в себя распознавание поврежденных/здоровых плодов и их классификацию. Высокоуровневая обработка включает в себя использование алгоритмов глубокого обучения.






Рис. 6. Алгоритм обработки панорамных снимков

В каждом из 3 типов обработки идет непрерывное взаимодействие с базой данных (базой знаний) в которой хранятся необходимые материалы (коэффициенты моделей, примеры для обучения и классификации) для выполнения точной классификации. Для повышения качества автоматизации процесса контроля качества плодов базу знаний необходимо пополнять материалами и периодически пересчитывать коэффициенты моделей.

Заключение. В рамках данного исследования проведена многоклассовая классификация здоровых и пораженных болезнями плодов колонновидной яблони сортов Президент, Останкино, Валюта, Червонец, Лукомор, Малюха. Сенатор, Триумф. Разработанная нейронная сеть позволяет вести обработку не менее 200 запросов, идентифицировать на изображениях кроны деревьев здоровые плоды яблони и плоды яблони, пораженные болезнями, вести подсчет их количества.

Предложен метод мониторинга рядов насаждений путем съемки панорамных снимков высокого разрешения. Использование панорамных штативных головок и методов оптимизации кадров позволят изменять положение камеры при мониторинге насаждений и программно выравнивать горизонт полученной панорамы, что дополнительно повысит точность полученных результатов.

Разработанное решение позволит оперативно выдавать практические рекомендации для нацеленного проведения агротехнических мероприятий по возделыванию и защите растений в современном промышленном саду, что обеспечит снижение затрат труда, экономию ресурса техники, удобрений и средств защиты растений при повышении качества плодов и обеспечит прогнозирование рисков для насаждений и урожая путем выдачи рекомендаций по предотвращению или смягчению их негативных последствий.



1. Jayme G., Arnal B. A review on the main challenges in automatic plant disease identification based on visible range images // *Biosystems Engineering*. 144:52-60. 2016.
2. Traversari S., Cacini S., Galieni A., Nesi B., Nicastro N., Pane C. Precision Agriculture Digital Technologies for Sustainable Fungal Disease Management of Ornamental Plants // *Sustainability*. 2021. 13. 3707.
3. Mohanty S.P., Hughes D.P., Salathé M. Using deep learning for image-based plant disease detection // *Frontiers in Plant Scienc.* 2016. 7:1419.
4. Shurygin B., Smirnov I., Chilikin A., Khort D., Kutyrev A., Zhukovskaya S., Solovchenko A. Mutual Augmentation of Spectral Sensing and Machine Learning for Non-Invasive Detection of Apple Fruit Damages // *Horticulturae*. 2022. 8. 1111.
5. Tan W.X., Zhao C.J., Wu H.R. CNN intelligent early warning for apple skin lesion image acquired by infrared video sensors // *High Technol. Lett.* 2016. 22. pp. 67-74.
6. Smirnov I., Kutyrev A., Kiktev N. Neural network for identifying apple fruits on the crown of a tree // *E3S Web of Conferences, WFCES 2021*. 2021. C. 01021.
7. Naranjo-Torres J., Mora M., Hernández-García R., Barrientos R.J., Fredes C. Valenzuela A. A. Review of Convolutional Neural Network Applied to Fruit Image Processing // *Appl. Sci.* 2020. 10. 3443.
8. Kutyrev A., Kiktev N., Jewiarz M., Khort D., Smirnov I., Zubina V., Hutsol T.; Tomasik M., Biliuk M. Robotic Platform for Horticulture: Assessment Methodology and Increasing the Level of Autonomy // *Sensors*. 2022. 22. 8901.
9. Liu J., Wang X. W. Plant diseases and pests detection based on deep learning: A review // *Plant Methods*. 2021. 17(1).
10. Maxwell A., Warner T., Guillén L. Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies. Part 1: Literature Review // *Remote Sens*. 2021. 13. 2450.

REFERENCES

1. Jayme G., Arnal B. A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems Engineering*. 2016. 144:52-60.
2. Traversari S., Cacini S., Galieni A., Nesi B., Nicastro N., Pane C. Precision Agriculture Digital Technologies for Sustainable Fungal Disease Management of Ornamental Plants. *Sustainability*. 2021. 13. 3707.
3. Mohanty S.P., Hughes D.P., Salathé M. Using deep learning for image-based plant disease detection. *Frontiers in Plant Scienc.* 2016. 7:1419.
4. Shurygin B., Smirnov I., Chilikin A., Khort D., Kutyrev A., Zhukovskaya S., Solovchenko A. Mutual Augmentation of Spectral Sensing and Machine Learning for Non-Invasive Detection of Apple Fruit Damages. *Horticulturae*. 2022. 8. 1111.
5. Tan W.X., Zhao C.J., Wu H.R. CNN intelligent early warning for apple skin lesion image acquired by infrared video sensors. *High Technol. Lett.* 2016. 22. pp. 67-74.
6. Smirnov I., Kutyrev A., Kiktev N. Neural network for identifying apple fruits on the crown of a tree. *E3S Web of Conferences, WFCES 2021*. 2021. C. 01021.
7. Naranjo-Torres J., Mora M., Hernández-García R., Barrientos R.J., Fredes C. Valenzuela A. A. Review of Convolutional Neural Network Applied to Fruit Image Processing. *Appl. Sci.* 2020. 10. 3443.
8. Kutyrev A., Kiktev N., Jewiarz M., Khort D., Smirnov I., Zubina V., Hutsol T.; Tomasik M., Biliuk M. Robotic Platform for Horticulture: Assessment Methodology and Increasing the Level of Autonomy. *Sensors*. 2022. 22. 8901.
9. Liu J., Wang X. W. Plant diseases and pests detection based on deep learning: A review. *Plant Methods*. 2021. 17(1).
10. Maxwell A., Warner T., Guillén L. Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies. Part 1: Literature Review. *Remote Sens*. 2021. 13. 2450.

Статья поступила в редакцию 6.02.2023; одобрена после рецензирования 2.03.2023; принята к публикации 12.03.2023.
The article was submitted 6.02.2023; approved after reviewing 2.03.2023; accepted for publication 12.03.2023.

