

doi 10.18699/vjgb-26-97

Обнаружение болезней земляники садовой с помощью БПЛА на основе сегментации мультиспектральных изображений методами глубокого машинного обучения

А.Ф. Чешкова , В.С. Риксен  , О.В. Елкин

Сибирский федеральный научный центр агробиотехнологий Российской академии наук, р. п. Краснообск, Новосибирская область, Россия

 riksenvs@sfscs.ru

Аннотация. Точная и своевременная диагностика болезней земляники садовой является важной задачей, позволяющей минимизировать потери урожая и снизить затраты на обработку растений. Использование беспилотных летательных аппаратов (БПЛА) с мультиспектральными камерами открывает новые возможности для неинвазивного мониторинга состояния растений. Цель настоящего исследования – анализ возможности выявления заболеваний земляники садовой (на примере белой пятнистости, возбудитель *Ramularia tulasnei* Sacc.) по мультиспектральным изображениям, полученным с БПЛА, с использованием методов глубокого машинного обучения. Съемка опытного участка (37×22 м) проводилась квадрокоптером DJI Phantom 4 Multispectral на высоте 3 м (разрешение 2.2 мм/пиксель). Полученные данные прошли предварительную обработку, включая построение ортофотоплана в программе Agisoft Metashape Pro и ручное выделение областей интереса (ROI) в ENVI 5.2. Сформирован набор из 360 мультиспектральных изображений размером 64×64×5 (каналы 450, 560, 650, 730, 840 нм) с тремя классами: здоровые растения, больные растения и почва. На данном наборе была обучена модель архитектуры U-Net (с модулями attention gate, squeeze-and-excitation и residual connections). Дополнительно для оценки вклада мультиспектральных каналов обучены U-Net модель на RGB-изображениях, а также классическая модель Random Forest на основе 40 текстурных признаков GLCM. Модель U-Net, обученная на мультиспектральных данных, достигла общей точности классификации 96.04 %, что существенно выше показателей Random Forest (76.64 %) и U-Net на RGB-изображениях (94.14 %). Полученные карты распространения болезни позволяют проводить точечное применение фунгицидов. Предложенный подход подтвердил эффективность глубокого обучения для диагностики белой пятнистости земляники. Дальнейшие исследования будут направлены на расширение набора данных (разные сорта и стадии болезней), апробацию более современных архитектур сегментации и масштабирование метода на промышленные плантации.

Ключевые слова: земляника садовая; белая пятнистость; БПЛА; мультиспектральная съемка; глубокое обучение; U-Net; семантическая сегментация; точное земледелие

Для цитирования: Чешкова А.Ф., Риксен В.С., Елкин О.В. Обнаружение болезней земляники садовой с помощью БПЛА на основе сегментации мультиспектральных изображений методами глубокого машинного обучения. Вавиловский журнал генетики и селекции. 2026;30(6):964-972. doi 10.18699/vjgb-26-97

UAV-based disease detection in strawberry by multispectral image segmentation invoking deep learning

A.F. Cheshkova , V.S. Riksen  , O.V. Elkin

Siberian Federal Scientific Center of AgroBioTechnologies of the Russian Academy of Sciences, Krasnoobsk, Novosibirsk region, Russia

 riksenvs@sfscs.ru

Abstract. Accurate and timely diagnosis of strawberry diseases is crucial for minimizing crop loss and reducing the cost of plant treatment. The use of unmanned aerial vehicles (UAVs) equipped with multispectral cameras opens up new possibilities for noninvasive plant health monitoring. The objective of this research is to explore the feasibility of detecting diseases in strawberries through multispectral imagery obtained from UAVs combined with deep learning techniques. Leaf spot disease, caused by *Ramularia tulasnei* Sacc., was chosen as a case study. A DJI Phantom 4 Multispectral quadcopter was used to survey an experimental plot (37×22 m) from an altitude of 3 m, achieving a resolution of 2.2 mm per pixel. Preprocessing of the acquired data involved orthomosaic building using Agisoft Metashape Pro and manual region-of-interest (ROI) extraction in ENVI 5.2. A dataset comprising 360 multispectral images, each of size 64×64×5 (with spectral bands at 450, 560, 650, 730, and 840 nm), was created and separated into three classes: healthy plants, diseased plants, and soil. Using this dataset, a U-Net-based model – supplemented with the attention gate, squeeze-and-excitation, and residual connections modules – was trained. Additionally, to assess the contribution of multispectral channels, another U-Net model was trained on RGB images, as well as a classic Random

Forest model based on 40 GLCM texture features. The U-Net model trained on multispectral data achieved an overall classification accuracy of 96.04 %, which is significantly higher than the performance of Random Forest (76.64 %) and the U-Net on RGB images (94.14 %). The resulting disease distribution maps enable site-specific fungicide application. The proposed approach confirmed the effectiveness of deep learning for diagnosing leaf spot disease in strawberries. Future research will focus on expanding the dataset (different cultivars and disease stages), testing more advanced segmentation architectures, and scaling the method to commercial plantations.

Key words: strawberry; leaf spot disease; UAV; multispectral imaging; deep learning; U-Net; semantic segmentation; precision agriculture

For citation: Cheshkova A.F., Riksen V.S., Elkin O.V. UAV-based disease detection in strawberry by multispectral image segmentation invoking deep learning. *Vavilovskii Zhurnal Genetiki i Selekcii* = *Vavilov J Genet Breed.* 2026;30(6):964-972. doi 10.18699/vjgb-26-97

Введение

Мониторинг состояния сельскохозяйственных растений с помощью беспилотных летательных аппаратов (БПЛА) – одна из важнейших технологий в современном точном земледелии (Radoglou-Grammatikis et al., 2020). Потенциал БПЛА продемонстрирован в ряде приложений, таких как обнаружение стрессов растений, картографирование полей, оценка биомассы, борьба с сорняками, подсчет популяции растений (Toscano et al., 2024). Повышенная эффективность, стабильность, точность и производительность – преимущества БПЛА, позволяющие фермерам и экспертам принимать более обоснованные и своевременные управленческие решения (Phang et al., 2023).

Благодаря использованию различных видов датчиков, устанавливаемых на БПЛА, стало возможным выявление различных аспектов состояния растений.

Так, изображения в видимом и ближнем инфракрасном диапазоне позволяют оценивать морфологию отдельных органов или целого растения, динамику роста, накопление биомассы, показатели урожайности, степень поражения вредителями и болезнями (Чешкова, 2022; Zahir et al., 2022). Изображения, полученные с помощью автофлуоресценции хлорофилла, помогают определить общий биоэнергетический статус растения, а также генетическую устойчивость к стрессорам (Moustakas et al., 2021). Съемка в инфракрасном диапазоне используется для определения температуры растений, оценки водного статуса, степени поражения насекомыми (Hou et al., 2022). Лазерное сканирование и 3D-изображения применяются для определения морфологии семян, ориентации листьев, структуры кроны, архитектуры корней, линейных размеров растения (Jin et al., 2021).

Одна из важных и распространенных задач полевого мониторинга – обнаружение заболеваний растений на изображениях, полученных с помощью БПЛА (Neupane, Baysal-Gurel, 2021). Среди датчиков, устанавливаемых на БПЛА, для идентификации заболеваний преимущественно используются мультиспектральные камеры. Спектральная информация изображений, полученных с помощью этих камер, позволяет рассчитать различные вегетационные индексы (ВИ), отражающие биофизические и биохимические свойства растений, которые изменяются в ответ на различные стрессы (Candiago et al., 2015). Данные индексы помогают охарактеризовать эти изменения и представляют собой один из наиболее важных факторов для идентифи-

кации болезней сельскохозяйственных культур (Mahlein et al., 2013).

Применимость мультиспектральных данных не ограничивается вычислением спектральных индексов. Более эффективный и точный способ анализа изображений – использование методов машинного обучения. Данные методы можно условно разделить на две группы.

В классических методах машинного обучения (SVM, Random Forest, KNN) эксперт должен вручную создавать и отбирать признаки из сырых данных (Behmann et al., 2015; Singh et al., 2016). Качество модели сильно зависит от информативности этих признаков. Несмотря на свои достоинства, эти алгоритмы могут быть применены только к табличным данным, что затрудняет их использование для обнаружения заболеваний растений по изображениям или видеоматериалам (Benos et al., 2021).

В методах глубокого машинного обучения (U-Net, SegNet, ResNet) происходит автоматическое извлечение признаков. Нейронная сеть сама находит иерархии признаков, извлекая их из сырых данных (Мударисов, Мифтахов, 2024; Sajitha et al., 2024). Эти методы позволяют обрабатывать изображения и видеоматериалы, чтобы научиться обнаруживать и классифицировать симптомы заболеваний растений (Loey et al., 2020; Nagaraju, Chawla, 2020; Abade et al., 2021).

Основные виды задач, решаемые при анализе изображений с применением методов машинного обучения, – это сегментация, классификация и детекция (Saleem et al., 2019; Ding et al., 2024).

Обнаружение стрессов растений по БПЛА снимкам является задачей семантической сегментации, когда для каждого пикселя на изображении необходимо установить его принадлежность к определенной категории (почва, здоровые или больные растения) и, таким образом, составить карту распространения заболеваний на поле.

Среди ягодных культур земляника садовая (*Fragaria × ananassa*) занимает первое место по производству и потреблению в мире. На ее долю приходится свыше 70 % общемирового производства ягод (Ожерельев и др., 2019). Точная своевременная и неинвазивная диагностика болезней и абиотических стрессов земляники имеет важное значение в ее промышленном производстве, так как позволяет минимизировать потери урожая и снизить затраты на обработку растений (Zheng et al., 2021).

Цель настоящего исследования – анализ возможности выявления заболеваний земляники садовой по мультиспектральным изображениям, полученным с помощью БПЛА, с использованием методов глубокого машинного обучения.

Материалы и методы

Растительный материал. Материалом исследования были растения земляники садовой, выращиваемые в коллекционном питомнике СибФТИ СФНЦА РАН. На участке размером 37×22 м находились растения сорта «Фестивальная» трехлетнего возраста. Растения высажены рядами шириной 50 см; расстояние между рядами 70 см. На дату съемки значительная часть растений была поражена заболеванием белая пятнистость (возбудитель *Ramularia tulasnei* Sacc.). С помощью визуального осмотра было отобрано 80 здоровых растений и 80 растений, имеющих видимые симптомы поражения листьев. Отобранные растения были помечены табличками розового и голубого цвета соответственно (рис. 1).

Получение изображений. Съемка осуществлялась с помощью квадрокоптера DJI Phantom 4 Multispectral (SZ DJI Technology Co., Ltd., Shenzhen, Китай). Установленная на дроне камера имеет одну матрицу видимого излучения RGB и пять монохромных (синий, зеленый, красный, край красного спектра, ближний инфракрасный), включающих длины волн 450, 560, 650, 730 и 840 нм соответственно.

Съемка проведена 15.07.2025 при пасмурной погоде на высоте 3 м. Разрешение съемки составило 2.2 мм/пиксель. В результате съемки получено 2170 снимков с перекрытием 75 % в продольном и 60 % в поперечном направлениях.

Предварительная обработка изображений и формирование наборов данных. Монохромные мультиспектральные камеры снимают каждый спектральный канал отдельным сенсором в разные моменты времени. Из-за движения дрона и вибраций эти каналы не совпадают по пиксельно на сырых кадрах. Перед началом обучения моделей необходимо привязать все спектральные каналы к единой системе координат и создать мультиспектральный растр, где в каждом пикселе присутствуют все нужные длины волн. Без этого этапа нейросеть не сможет корректно извлекать спектральные признаки, так как пиксели разных каналов будут относиться к разным точкам местности.

Первым этапом обработки снимков, полученных с помощью пяти монохромных камер PM4, была сборка единого мультиспектрального изображения (ортофотоплана) опытного участка. Для данной цели использовалась программа Agisoft Metashape Pro (Agisoft LLC, Россия). Результирующее изображение опытного участка было сформировано в формате GeoTIFF с разрешением $15000 \times 20000 \times 5$, размером 2.9 Гб.

Второй этап – разметка изображений. На полученном ортофотоплане вручную были выделены параллельные осям прямоугольные области интереса (ROI) размером $64 \times 64 \times 5$, содержащие помеченные табличками больные и здоровые растения, а также области почвы (сами таблички в ROI не включали). Из каждой выделенной области был создан отдельный файл изображения (рис. 2). Выделение ROI и формирование изображений выполняли в программе ENVI 5.2 (ITT Visual Information Solutions).




Рис. 1. Растения земляники: а – пораженные белой пятнистостью; б – здоровые.



Рис. 2. Выделенные из изображений области: а – растения, пораженные белой пятнистостью; б – здоровые растения; в – почва.




Рис. 3. Архитектура U-Net, реализованная в пакете geodl.

Блоки с префиксом E обозначают блоки энкодера, а блоки с префиксом D – блоки декодера; w – ширина; h – высота.

Таким образом, сформирован набор данных из 360 мультиспектральных изображений (по 120 на каждый класс). Из них 240 – обучающая выборка, 60 – валидационная, 60 – тестовая.

В целях сравнения точности моделей был подготовлен второй набор данных для анализа, составленный из RGB-изображений. Отличие заключалось в том, что ROI выделялись на исходных снимках, полученных с RGB-камеры PM4, без формирования ортофотоплана. Набор данных RGB также содержит 360 изображений размером $64 \times 64 \times 3$.

Для сравнения с классическими методами машинного обучения был сформирован дополнительный набор табличных данных по следующему алгоритму. Для каждого мультиспектрального изображения ($64 \times 64 \times 5$) из обучающей выборки отдельно по каждому из пяти монохромных каналов попиксельно методом скользящего окна было рассчитано по восемь текстурных характеристик (среднее, дисперсия, гомогенность, контраст, несходство, энтропия, второй момент, корреляция) на основе матрицы совместной встречаемости уровней серого GLCM (Li et al., 2019; Guo et al., 2021; Zhou et al., 2022).

Был выбран наименьший размер окна (3×3 пикселя). Для пикселей локальной области, выходящей за пределы изображения на крае, значения текстурных характеристик устанавливали в NA (not available). Относительное расстояние, измеренное в пикселях (d) в GLCM, было установлено равным 1 ($d = 1$). Матрицы вычислялись для четырех направлений: $\Theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$, характери-

сти усреднялись по этим направлениям. Итоговая таблица для каждого изображения содержала $64 \times 64 = 4096$ строк, $8 \times 5 = 40$ столбцов текстурных характеристик и столбец класса (здоровый, больной, почва). Далее из этих таблиц случайным образом выбирали по 1000 пикселей, не содержащих NA значения. Таким образом, набор данных для обучения составил 240000 строк (по 80000 в каждом классе). Размер валидационной и тестовой выборки – по 60000 строк.

Методы моделирования и анализа данных. Все расчеты и анализ данных проведены в программной среде R с использованием пакетов torch, geodl, randomForest, terra.

В нашем исследовании рассмотрены две модели машинного обучения: модель глубокого обучения U-Net (Ronneberger et al., 2015) и классическая модель Random Forest (Breiman, 2001).

Сверточная нейронная сеть U-Net – одна из наиболее популярных архитектур для решения задач семантической сегментации (Kerkech et al., 2020; Zhang T. et al., 2021). Знаменитая U-образная архитектура сети с сужающимся контуром (кодировщиком) для захвата контекста и симметричным расширяющимся контуром (декодером) для точной локализации, а также «пропускаемые связи» между кодировщиком и декодером позволяют сети объединять высокоуровневые признаки с детальной пространственной информацией, что приводит к созданию высокоточных карт сегментации даже при ограниченном объеме обучающих данных.

Мы использовали архитектуру U-Net, представленную на рис. 3 и реализованную в пакете geodl (Maxwell et al., 2024). Она может принимать переменное количество входных предикторных переменных (т.е. подходит как для RGB, так и для мультиспектральных изображений). Архитектура включает четыре кодирующих блока, один узловой блок и четыре декодирующих блока. Количество выходных карт признаков установлено (16, 32, 64, 128) в кодирующих блоках и (128, 64, 32, 16) в декодирующих блоках. Во всей архитектуре использовали функции активации ReLU для внесения нелинейности, а также применяли пакетную нормализацию для борьбы с проблемами градиентов и ускорения сходимости.

В кодировщике размер массива в пространственных измерениях уменьшается вдвое после каждого блока с помощью операции максимального пулинга 2×2 и с шагом 2. В декодировщике используется двумерная транспонированная свертка для удвоения пространственного разрешения карт признаков, полученных от предыдущего блока; так же с шагом 2. Финальные классы предсказываются с помощью двумерной свертки 1×1 . К основным блокам архитектуры U-Net были добавлены модули attention gate, squeeze-and-excitation и residual connections.

Классическая модель Random Forest, основанная на использовании ансамбля решающих деревьев, также часто применяется для решения задач дистанционного зондирования, в том числе для обнаружения и классификации болезней растений (Lan et al., 2020; Liao et al., 2022; Zhang S. et al., 2022). На предыдущем этапе исследований мы выяснили, что для решения задачи обнаружения болезней земляники по мультиспектральным снимкам методом Random Forest наилучшие результаты получаются при использовании набора текстурных характеристик в качестве информативных признаков (Чешкова, Риксен, 2025).

Метрики качества моделей. Для оценки качества сегментации использовали стандартные критерии, вычисляемые отдельно для каждого класса: Accuracy, Precision, Recall, F1-score и IoU. Их расчет основан на элементах матрицы ошибок: TP (true positive) – число пикселей рассматриваемого класса, правильно отнесенных моделью к этому классу; TN (true negative) – число пикселей остальных классов, правильно не отнесенных к рассматриваемому классу; FP (false positive) – число пикселей других классов, ошибочно отнесенных к рассматриваемому классу; FN (false negative) – число пикселей рассматриваемого класса, ошибочно отнесенных к другим классам.

Ассурасу (доля правильных классификаций) характеризует долю всех пикселей, классифицированных правильно при оценке конкретного класса по схеме «данный класс – остальные классы». Она учитывает как правильно распознанные пиксели данного класса, так и правильно отнесенные к другим классам пиксели. Чем ближе Ассурасу к 1 (100 %), тем выше правильность классификации.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}.$$

Precision (точность) показывает, какая доля пикселей, отнесенных моделью к рассматриваемому классу, дей-

ствительно принадлежит к этому классу. Высокое значение Precision соответствует малому числу ложноположительных срабатываний.

$$\text{Precision} = \frac{TP}{TP + FP}.$$

Recall (полнота, чувствительность) характеризует долю пикселей рассматриваемого класса, которые модель правильно обнаружила среди всех пикселей, фактически принадлежащих к этому классу. Высокий Recall означает малое число ложноотрицательных результатов, т.е. пропусков пикселей данного класса.

$$\text{Recall} = \frac{TP}{TP + FN}.$$

F1-score представляет собой гармоническое среднее Precision и Recall и используется для их совместной оценки. Высокое значение F1-score возможно только при одновременных высоких значениях точности и полноты, поэтому метрика учитывает как ложноположительные, так и ложноотрицательные ошибки.

$$\text{F1 score} = \frac{2TP}{2TP + FN + FP}.$$

IoU (intersection over union – пересечение над объединением) характеризует степень совпадения предсказанной моделью маски класса с эталонной маской. В числителе находится область их пересечения, а в знаменателе – объединение предсказанной и эталонной областей. Значение IoU, близкое к 1, соответствует высокому пространственному совпадению сегментации с эталонной разметкой.

$$\text{IoU} = \frac{TP}{TP + FN + FP}.$$

Overall Accuracy (ОА, общая точность классификации) оценивает качество классификации одновременно по всем классам и определяется как отношение суммарного числа правильно классифицированных пикселей всех классов к общему числу пикселей. В отличие от Accuracy, рассчитываемой отдельно для каждого класса, Overall Accuracy является единой итоговой характеристикой многоклассовой классификации изображения.

Результаты

Обучение и валидация моделей

При обучении U-Net моделей использован оптимизатор Adam, функция потерь CrossEntropyLoss. В процессе обучения проводились нормализация по среднему и дисперсии (Z-score) и аугментация данных (горизонтальное или вертикальное отражение с вероятностью 0.5 и случайный поворот на 0, 90, 180 или 270 градусов). Модели обучались в течение 50 эпох с начальной скоростью обучения 0.001.

Для сравнения было использовано два обучающих набора данных – мультиспектральные изображения и RGB-изображения. На рис. 4–5 представлена динамика процесса обучения модели U-Net на разных наборах данных.

При обучении модели Random Forest установлены следующие параметры: количество деревьев – 500, минимальный размер терминальных узлов – 1, количество переменных, случайно выбранных в качестве кандидатов при каждом разбиении, – 6.




Рис. 4. Графики изменения точности и потерь обучения модели U-Net на мультиспектральных изображениях.




Рис. 5. Графики изменения точности и потерь обучения модели U-Net на RGB-изображениях.

Таблица 1. Метрики качества U-Net модели, обученной на мультиспектральных снимках

Класс/метрика	Accuracy	Precision	Recall	F1	IoU
Почва	0.9996	0.9994	0.9994	0.9994	0.9989
Больные	0.9603	0.9370	0.9445	0.9408	0.8882
Здоровые	0.9607	0.9446	0.9370	0.9408	0.8883
Среднее	0.9735	0.9603	0.9603	0.9603	0.9251

Общая точность классификации – 96.04 %.

Таблица 2. Метрики качества U-Net модели, обученной на RGB-снимках

Класс/метрика	Accuracy	Precision	Recall	F1	IoU
Почва	1	1	1	1	1
Больные	0.9414	0.9211	0.9015	0.9112	0.8370
Здоровые	0.9414	0.9036	0.9228	0.9131	0.8401
Среднее	0.9609	0.9416	0.9414	0.9414	0.8923

Общая точность классификации – 94.14 %.

Таблица 3. Метрики качества Random Forest модели, обученной на текстурных характеристиках мультиспектральных снимков

Класс/метрика	Accuracy	Precision	Recall	F1	IoU
Почва	0.9563	0.9174	0.9549	0.9358	0.8794
Больные	0.7968	0.7364	0.6078	0.6660	0.4992
Здоровые	0.7798	0.6496	0.7365	0.6903	0.5271
Среднее	0.8443	0.7678	0.7664	0.7641	0.6352

Общая точность классификации – 76.64 %.

Обученные модели оценены на тестовых выборках. В табл. 1–3 представлены метрики качества моделей. Общая точность классификации U-Net модели, обученной на мультиспектральных снимках, составила 96.04 %. Немного ниже точность классификации U-Net модели,

обученной на RGB-снимках, – 94.14 %. Значительно ниже точность модели Random Forest – всего 76.64 %. Обученные модели были применены для сегментации изображений и построения карт распространения грибных болезней земляники на экспериментальном поле (рис. 6).




Рис. 6. Результат сегментации изображений обученными моделями.
Зеленый цвет – здоровые растения; красный – больные растения; белый – почва.

Обсуждение

В настоящем исследовании оценена возможность выявления болезней земляники садовой (на примере белой пятнистости) по мультиспектральным изображениям, полученным с БПЛА, с использованием архитектуры глубокого обучения U-Net и классического метода Random Forest. Полученные результаты показали, что модель U-Net, обученная на мультиспектральных данных (5 каналов: 450, 560, 650, 730, 840 нм), достигла общей точности классификации 96.04 %, что превосходит точность модели Random Forest (76.64 %) и модели U-Net, обученной только на RGB-изображениях (94.14 %).

Достигнутая точность U-Net (96.04 %) сопоставима или превышает результаты, полученные в других работах по обнаружению болезней сельскохозяйственных культур с помощью БПЛА и глубокого обучения. Например, J. Su с коллегами (2020) и T. Zhang с коллегами (2021) достигли точности 91 и 97 % соответственно при обнаружении желтой ржавчины пшеницы с использованием модификаций U-Net. M. Kerkech с коллегами (2020) показали диапазон точности 85–94 % для различных архитектур (SegNet, DeepLabv3+, PSPNet) при диагностике болезней винограда. Таким образом, наша модель находится на верхней границе этого диапазона, что подтверждает пригодность U-Net для задач фитопатологии земляники.

Более высокая точность мультиспектральной U-Net по сравнению с RGB-версией (96.04 против 94.14 %) объясняется тем, что дополнительные каналы (край красного – 730 нм и ближний ИК – 840 нм) чувствительны к изменениям содержания хлорофилла, структуры мезофилла и водного статуса листа, которые происходят даже при начальных стадиях грибной инфекции до появления видимых пятен. Этот результат согласуется с выводами А.-К. Mahlein с коллегами (2013) и S. Candiago с коллегами (2015) о важности спектральных каналов за

пределами видимого диапазона для ранней диагностики стрессов.

Модель Random Forest, построенная на 40 текстовых признаках GLCM, показала низкую точность (76.64 %), что заметно уступает результатам других исследований, где Random Forest применялся для обнаружения болезней растений: (Liao et al., 2022) – 90 % для болезни эвкалипта; (Zhang S. et al., 2022) – 97 % для фузариозного увядания бананов. Мы связываем это с особенностью симптоматики белой пятнистости земляники: на листьях формируются мелкие (1–5 мм) некротические пятна, не приводящие к глобальному изменению цвета или текстуры всего листа. В отличие от этого, при фузариозном увядании бананов или болезни эвкалипта наблюдается массовое изменение окраски целых листовых пластинок, что хорошо улавливается текстурными признаками на уровне пиксельных окрестностей. GLCM-признаки, рассчитанные для локального окна (в нашем случае – вокруг каждого пикселя), оказались недостаточно чувствительными к мелкоочаговым поражениям.

Полученные результаты убедительно демонстрируют, что глубокое обучение на мультиспектральных БПЛА-снимках является эффективным инструментом для обнаружения белой пятнистости земляники. Преимущество U-Net над Random Forest и над RGB-каналами подтверждает необходимость использования как спектральной информации за пределами видимого диапазона, так и архитектур с автоматическим извлечением признаков.

Предполагаемые направления будущих исследований:

- расширение набора данных, включение большего числа сортов, разных стадий заболевания, а также других болезней земляники;

- сравнение U-Net с более современными архитектурами сегментации (Swin-UNet, TransUNet, Mask2Former) для оценки потенциального прироста точности;

- исследование возможности переноса обучения (transfer learning) с использованием предварительно обученных на крупных наборах данных (PlantCLEF, Agrivision) моделей для снижения потребности в размеченных данных;
- внедрение временных рядов мультиспектральных снимков (съемка каждые 3–5 дней) для раннего обнаружения болезни до появления видимых симптомов.

Заключение

В результате исследования подтверждена возможность автоматизированного обнаружения белой пятнистости земляники садовой по мультиспектральным изображениям с БПЛА. Модель глубокого обучения U-Net достигла общей точности классификации 96.04 %, что значительно превзошло результат модели Random Forest (76.64 %) и U-Net, обученной только на RGB-снимках (94.14 %). Это доказывает, что архитектура U-Net с механизмами внимания и остаточными связями, а также использование ближнего инфракрасного канала (840 нм) и канала «край красного» (730 нм) являются важными для диагностики заболеваний с мелкоочаговой симптоматикой, когда традиционные текстурные признаки малоинформативны.

Практическая значимость настоящей работы заключается в возможности построения детальных карт распространения инфекции для точечного применения фунгицидов.

Список литературы / References

- Мударисов С.Г., Мифтахов И.Р. Методы глубокого обучения и технологии БПЛА для идентификации заболеваний сельскохозяйственных растений. *Сельскохозяйственные машины и технологии*. 2024;18(4):24-33. doi 10.22314/2073-7599-2024-18-4-24-33 [Mudarisov S.G., Miftakhov I.R. Deep learning methods and UAV technologies for crop disease detection. *Sel'skokhozyajstvennyye Mashiny i Tekhnologii = Agricultural Machinery and Technologies*. 2024;18(4):24-33. doi 10.22314/2073-7599-2024-18-4-24-33 (in Russian)]
- Ожерельев В.Н., Ожерельева М.В., Гринь А.М., Сомин В.В. Динамика производства ягод земляники садовой по странам мира. *Вестник Брянской ГСХА*. 2019;4(74):60-66 [Ozherelev V.N., Ozhereleva M.V., Grin A.M., Somin V.V. Dynamics of garden strawberries production all over the world. *Vestnik of the Bryansk State Agricultural Academy*. 2019;4(74):60-66 (in Russian)]
- Чешкова А.Ф. Обзор современных методов обнаружения и идентификации болезней растений на основе анализа гиперспектральных изображений. *Вавиловский журнал генетики и селекции*. 2022;26(2):202-213. doi 10.18699/VJGB-22-25 [Cheshkova A.F. A review of hyperspectral image analysis techniques for plant disease detection and identification. *Vavilovskii Zhurnal Genetiki i Selekcii = Vavilov J Genet Breed*. 2022;26(2):202-213. doi 10.18699/VJGB-22-25]
- Чешкова А.Ф., Риксен В.С. Обнаружение болезней земляники садовой с использованием мультиспектральной съемки с БПЛА. *Сельскохозяйственные машины и технологии*. 2025;19(2):45-52. doi 10.22314/2073-7599-2025-19-2-45-52 [Cheshkova A.F., Riksen V.S. Strawberry disease detection using multispectral UAV imagery. *Sel'skokhozyajstvennyye Mashiny i Tekhnologii = Agricultural Machinery and Technologies*. 2025;19(2):45-52. doi 10.22314/2073-7599-2025-19-2-45-52 (in Russian)]
- Abade A., Ferreira P.A., Vidal F.B. Plant diseases recognition on images using convolutional neural networks: a systematic review. *Comput Electron Agric*. 2021;185:106125. doi 10.1016/j.compag.2021.106125
- 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;16:239-260. doi 10.1007/s11119-014-9372-7
- Benos L., Tagarakis A.C., Dolias G., Berruto R., Kateris D., Bochtis D. Machine learning in agriculture: a comprehensive updated review. *Sensors*. 2021;21(11):3758. doi 10.3390/s21113758
- Breiman L. Random forest. *Mach Learn*. 2001;45:5-32. doi 10.1023/A:1010933404324
- Candiago S., Remondino F., De Giglio M., Dubbini M., Gattelli M. Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote Sens*. 2015;7(4):4026-4047. doi 10.3390/rs70404026
- Ding W., Abdel-Basset M., Alrashdi I., Hawas H. Next generation of computer vision for plant disease monitoring in precision agriculture: a contemporary survey, taxonomy, experiments, and future direction. *Inf Sci*. 2024;665:120338. doi 10.1016/j.ins.2024.120338
- Guo A., Huang W., Dong Y., Ye H., Ma H., Liu B., Wu W., Ren Y., Ruan C., Geng Y. Wheat yellow rust detection using UAV-based hyperspectral technology. *Remote Sens*. 2021;13(1):123. doi 10.3390/rs13010123
- Hou F.J., Zhang Y., Zhou Y., Zhang M., Lv B., Wu J.Q. Review on infrared imaging technology. *Sustainability*. 2022;14(18):26. doi 10.3390/su141811161
- Jin S.C., Sun X.L., Wu F.F., Su Y.J., Li Y.M., Song S.L., Xu K.X., Ma Q., Baret F., Jiang D. Lidar sheds new light on plant phenomics for plant breeding and management: recent advances and future prospects. *ISPRS J Photogramm Remote Sens*. 2021;171:202-223. doi 10.1016/j.isprsjprs.2020.11.006
- Kerkech M., Hafiane A., Canals R. VddNet: Vine Disease Detection Network based on multispectral images and depth map. *Remote Sens*. 2020;12(20):3305. doi 10.3390/rs12203305
- Lan Y., Huang Z., Deng X., Zhu Z., Huang H., Zheng Z., Lian B., Zeng G., Tong Z. Comparison of machine learning methods for citrus greening detection on UAV multispectral images. *Comput Electron Agric*. 2020;171:105234. doi 10.1016/j.compag.2020.105234
- Li S., Yuan F., Ata-UI-Karim S.T., Zheng H., Cheng T., Liu X., Tian Y., Zhu Y., Cao W., Cao Q. Combining color indices and textures of UAV-based digital imagery for rice LAI estimation. *Remote Sens*. 2019;11(15):1763. doi 10.3390/rs11151763
- Liao K., Yang F., Dang H., Wu Y., Luo K., Li G. Detection of eucalyptus leaf disease with UAV multispectral imagery. *Forests*. 2022;13(8):1322. doi 10.3390/f13081322
- Loey M., Elsayy A., Afify M. Deep learning in plant diseases detection for agricultural crops: a survey. *Int J Serv Sci Manage Eng Technol*. 2020;11(2):18. doi 10.4018/IJSSMET.2020040103
- Mahlein A.-K., Rumpf T., Welke P., Dehne H.-W., Plümer L., Steiner U., Oerke E.-C. Development of spectral indices for detecting and identifying plant diseases. *Remote Sens Environ*. 2013;128:21-30. doi 10.1016/j.rse.2012.09.019
- Maxwell A.E., Farhadpour S., Das S., Yang Y. geodl: an R package for geospatial deep learning semantic segmentation using torch and terra. *PLoS One*. 2024;19(12):e0315127. doi 10.1371/journal.pone.0315127
- Moustakas M., Calatayud Á., Guidi L. Chlorophyll fluorescence imaging analysis in biotic and abiotic stress. *Front Plant Sci*. 2021;12:658500. doi 10.3389/fpls.2021.658500
- Nagaraju M., Chawla P. Systematic review of deep learning techniques in plant disease detection. *Int J Syst Assur Eng Manage*. 2020;11(3):547-560. doi 10.1007/s13198-020-00972-1
- Neupane K., Baysal-Gurel F. Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: a review. *Remote Sens*. 2021;13(19):3841. doi 10.3390/rs13193841

- Phang S.K., Chiang T.H.A., Happonen A., Chang M.M.L. From satellite to UAV-based remote sensing: a review on precision agriculture. *IEEE Access*. 2023;11:127057-127076. doi 10.1109/ACCESS.2023.3330886
- Radoglou-Grammatikis P., Sarigiannidis P., Lagkas T., Moscholiou I. A compilation of UAV applications for precision agriculture. *Comput Networks*. 2020;172:107148. doi 10.1016/j.comnet.2020.107148
- Ronneberger O., Fischer P., Brox T. U-net: convolutional networks for biomedical image segmentation. In: Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Lecture Notes in Computer Science. Vol. 9351. Springer, 2015;234-241. doi 10.1007/978-3-319-24574-4_28
- Sajitha P., Andrushia A.D., Anand N., Naser M.Z. A review on machine learning and deep learning image-based plant disease classification for industrial farming systems. *J Ind Inf Integr*. 2024;38:100572. doi 10.1016/j.jii.2024.100572
- Saleem M.H., Potgieter J., Arif K.M. plant disease detection and classification by deep learning. *Plants*. 2019;8(11):468. doi 10.3390/plants8110468
- Singh A., Ganapathysubramanian B., Singh A.K., Sarkar S. Machine learning for high-throughput stress phenotyping in plants. *Trends Plant Sci*. 2016;21(2):110-124. doi 10.1016/j.tplants.2015.10.015
- Su J., Yi D., Su B., Mi Z., Liu C., Hu X., Xu X., Guo L., Chen W.H. Aerial visual perception in smart farming: field study of wheat yellow rust monitoring. *IEEE Trans Ind Inf*. 2020;17(3):2242-2249. doi 10.1109/TII.2020.2979237
- Toscano F., Fiorentino C., Capece N., Erra U., Travascia D., Scopa A., Drosos M., D'Antonio P. Unmanned aerial vehicle for precision agriculture: a review. *IEEE Access*. 2024;12:69188-69205. doi 10.1109/ACCESS.2024.3401018
- Zahir S.A.D.M., Omar A.F., Jamlos M.F., Azmi M.A.M., Muncan J. A review of visible and near-infrared (Vis-NIR) spectroscopy application in plant stress detection. *Sens Actuators A*. 2022;338:113468. doi 10.1016/j.sna.2022.113468
- Zhang S., Li X., Ba Y., Lyu X., Zhang M., Li M. Banana fusarium wilt disease detection by supervised and unsupervised methods from UAV-based multispectral imagery. *Remote Sens*. 2022;14(5):1231. doi 10.3390/rs14051231
- Zhang T., Xu Z., Su J., Yang Z., Liu C., Chen W.-H., Li J. Ir-UNet: irregular segmentation U-shape network for wheat yellow rust detection by UAV multispectral imagery. *Remote Sens*. 2021;13(19):3892. doi 10.3390/rs13193892
- 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;13(3):531. doi 10.3390/rs13030531
- Zhou C., Gong Y., Fang S., Yang K., Peng Y., Wu X., Zhu R. Combining spectral and wavelet texture features for unmanned aerial vehicles remote estimation of rice leaf area index. *Front Plant Sci*. 2022;13:957870. doi 10.3389/fpls.2022.957870

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию 13.04.2026. После доработки 15.06.2026. Принята к публикации 16.06.2026.