

EDN: LGIDJN

DOI: 10.22314/2073-7599-2025-19-2-45-52

Научная статья
УДК 632.08; 004.896

Обнаружение болезней земляники садовой с использованием мультиспектральной съемки с БПЛА

Анна Федоровна Чешкова,
кандидат физико-математических наук,
e-mail: cheshanna@yandex.ru;

Вера Сергеевна Риксен,
кандидат сельскохозяйственных наук,
e-mail: riclog@mail.ru

Сибирский федеральный научный центр агробиотехнологий РАН, р.п. Краснообск, Новосибирская обл., Российская Федерация

Реферат. Точная, своевременная и неинвазивная диагностика болезней имеет важное значение в промышленном производстве земляники, так как позволяет минимизировать потери урожая и снизить затраты на обработку растений. Благодаря развитию беспилотных летательных аппаратов и сенсорных технологий дистанционное зондирование становится перспективным способом мониторинга болезней сельскохозяйственных культур. Оперативное выявление заболеваний на ранних стадиях особенно важно для таких чувствительных культур, как земляника садовая. (*Цель исследования*) Анализ возможности обнаружения грибковых болезней земляники садовой в полевых условиях с применением мультиспектральных сенсоров и беспилотных летательных аппаратов. (*Материалы и методы*) В коллекционном питомнике СибФТИ СФНЦА РАН была выполнена аэрофотосъемка растений земляники, пораженных белой пятнистостью. Мультиспектральная камера была установлена на квадрокоптере *DJI Phantom4 Multispectral*. Полученные данные прошли предварительную обработку, включая построение ортофотоплана и извлечение спектральных и текстурных характеристик изображений. (*Результаты и обсуждение*) На основе анализа мультиспектральных данных выделены наборы информативных признаков для дифференциации здоровых и пораженных грибами растений. Методом случайного леса (*Random Forest*) построена модель для обнаружения болезней земляники с точностью классификации 77 процентов. (*Выводы*) Для повышения точности классификации необходимы дополнительные исследования с применением сенсоров, обладающих более высоким пространственным разрешением. Также перспективным направлением является разработка классификационных моделей на основе сверточных нейронных сетей, которые могут улучшить результаты за счет более глубокого анализа изображений. Полученные результаты подтверждают потенциал использования БПЛА и мультиспектральных технологий для мониторинга заболеваний сельскохозяйственных культур.

Ключевые слова: земляника садовая, грибковые болезни, диагностика, мультиспектральные изображения, беспилотный летательный аппарат, компьютерное зрение, машинное обучение

■ **Для цитирования:** Чешкова А.Ф., Риксен В.С. Обнаружение болезней земляники садовой с использованием мультиспектральной съемки с БПЛА // *Сельскохозяйственные машины и технологии*. 2025. Т. 19. №2. С. 45-52. DOI: 10.22314/2073-7599-2025-19-2-45-52. EDN: LGIDJN.

Scientific article

Strawberry Disease Detection Using Multispectral UAV Imagery

Anna F. Cheshkova,
Ph.D.(Phys.-Math.), leading researcher,
e-mail: cheshanna@yandex.ru;

Vera S. Riksen,
Ph.D.(Agri.), junior researcher,
e-mail: riclog@mail.ru

Siberian Federal Research Centre of Agro-BioTechnologies of the RAS, Krasnoobsk, Novosibirsk region, Russian Federation

Abstract. Accurate, timely, and non-invasive diagnosis of plant diseases is essential in the industrial cultivation of strawberries, as it helps minimize yield losses and reduce treatment costs. With the advancement of unmanned aerial vehicles and sensor technologies, remote sensing has emerged as a promising tool for monitoring crop health and detecting diseases. Early detection is especially important for sensitive crops such as garden strawberries. (*Research purpose*) The research aims to evaluate the potential of using multispectral sensors and unmanned aerial vehicles for detecting fungal diseases in garden strawberries under field conditions. (*Materials and methods*) Aerial imaging of strawberry plants affected by white leaf spot was carried out at the experimental nursery of the Siberian Federal Research Center for Agro-BioTechnologies of the RAS (SibFRC ABT RAS). A DJI

Phantom 4 Multispectral quadcopter equipped with a multispectral camera was used for data collection. The acquired imagery underwent preliminary processing, including orthophotomap generation and extraction of spectral and textural features from the images. (*Results and discussion*) Analysis of the multispectral data enabled the identification of informative feature sets for distinguishing between healthy and fungus-infected strawberry plants. A disease detection model developed using the Random Forest algorithm, achieved a classification accuracy of 77%. (*Conclusions*) To improve classification accuracy, further research involving sensors with higher spatial resolution is recommended. Another promising direction is the development of classification models based on convolutional neural networks, which offer improved performance through deeper image analysis. The results confirm the potential of UAV-based multispectral imaging for effective crop disease monitoring.

Keywords: garden strawberry, fungal diseases, diagnostics, multispectral imagery, unmanned aerial vehicle (UAV), computer vision, machine learning.

For citation: Cheshkova A.F., Riksen V.S. Strawberry disease detection using multispectral UAV imagery. *Agricultural Machinery and Technologies*. 2025. Vol. 19. N2. 45-52 (In Russian). DOI: 10.22314/2073-7599-2025-19-2-45-52. EDN: LGIDJN.

На долю земляники садовой приходится свыше 70% общемирового производства ягод. Это обусловлено ее высокими вкусовыми, диетическими и лечебными качествами, а с другой стороны, способностью к быстрому вегетативному размножению, скороплодностью, высокой рентабельностью и урожайностью. Один из главных сдерживающих факторов увеличения производства ягод земляники садовой состоит в значительном поражении возделываемых сортов земляники грибковыми болезнями (микозы), снижении продуктивности плантаций от 15 до 92% и их гибели (Говорова Г.Ф., Говоров Д.Н. Грибные болезни земляники садовой, селекция на иммунитет и другие методы защиты. М.: РГАУ-МСХА, 2015. 168 с.).

Диагностика болезней и их возбудителей – важное звено в системе защиты растений. В настоящее время быстрыми темпами развиваются новые неинвазивные методы диагностики болезней растений с использованием сенсорных технологий, робототехники, компьютерного зрения и машинного обучения [1-4]. Современные высокопроизводительные методы позволяют получать данные в режиме реального времени и анализировать информацию о целом спектре физиологических параметров.

Эти методы фокусируются на различиях оптических характеристик инфицированных и здоровых растений, регистрируемых различными сенсорами (RGB, мульти- и гиперспектральными) на спутниках, беспилотных летательных аппаратах (БПЛА) или наземных платформах [5]. Наиболее эффективным и недорогим решением для полевого мониторинга болезней растений на больших площадях является использование БПЛА, оборудованных оптическими сенсорами [6, 7].

Для анализа большого объема полученных данных, как правило, используют методы машинного обучения [8-10]. Различия спектральных характеристик здоровых и пораженных патогенами тканей листьев земляники служат основой для построения моделей классификации.

Множество исследований показывают, что использование вегетационных индексов в качестве информативных признаков позволяет добиться хороших результатов в выявлении и распознавании болезней сельскохозяйственных культур [11, 12]. Вегетационные индексы являются алгебраическими комбинациями, рассчитываемыми по спектрам отражения двух или более выбранных длин волн.

Когда для мониторинга заболеваний недостаточно спектральных показателей, важную роль в повышении точности классификации играют текстурные характеристики, описывающие пространственное распределение пикселей изображения [13, 14]. Эффективным методом извлечения текстурной информации является расчет матрицы совместной встречаемости уровней серого (*gray-level co-occurrence matrix*, *GLCM*) [15].

В научных публикациях приводятся примеры успешного применения сенсорных технологий и машинного обучения для обнаружения и диагностики заболеваний сельскохозяйственных культур. Так, в работе [11] приводится сравнение различных методов машинного обучения для обнаружения болезни цитрусового озеленения на основе анализа мультиспектральных снимков, полученных с БПЛА. В качестве исходных данных для обучения моделей используются комбинации спектральных значений, вегетационных индексов и главных компонент PCA.

Методы ансамблевого обучения и нейронной сети показали высокую надежность и лучшие результаты классификации (100% в *AdaBoost* и 97,28% в нейронной сети).

Проводятся исследования возможности обнаружения и дифференциации двух видов болезней винограда с использованием мультиспектральной камеры, установленной на БПЛА [11]. Методом анализа ROC-кривых были выбраны наиболее информативные спектральные каналы, вегетационные индексы и биофизические характеристики для дифференциации заболеваний.



Предлагается методика фенотипирования земляники с использованием мультиспектральных изображений с высоким разрешением на основе платформы БПЛА для изучения устойчивости земляники к вертициллезному увяданию [16].

В работе [17] изучали эффективность обнаружения болезней листьев в эвкалиптовом лесу с использованием мультиспектральных изображений высокого пространственного разрешения, полученных с помощью БПЛА. Результаты показали, что длины волн зеленого, красного и ближнего инфракрасного диапазона, индекс отражения азота и индекс зелени наиболее чувствительны к исследуемым болезням. Для дифференциации степени поражения листьев использовали алгоритм случайного леса (*Random Forest*), точность классификации составляла 90,1%.

В исследовании [18] выбирали модель классификации для определения различных стадий заболевания фузариозное увядание бананов по мультиспектральным данным. Точность классификации алгоритма случайного леса достигала 97%.

Нами не найдены публикации, посвященные обнаружению и диагностике современными средствами фенотипирования в полевых условиях таких грибковых болезней земляники, как белая, бурая и угловатая пятнистости, наиболее распространенных в условиях Западной Сибири.

Цель исследования: анализ возможности обнаружения грибковых болезней земляники садовой в полевых условиях с применением мультиспектральных сенсоров и беспилотных летательных аппаратов.

МАТЕРИАЛЫ И МЕТОДЫ.

Растительный материал. Материалом исследования были растения земляники садовой, выращиваемые в коллекционном питомнике СибФТИ СФНЦА РАН (р.п. Краснообск, Новосибирская обл.). На участке размером 57,5×12,4 м находились растения трехлетнего возраста, 45 разных сортов. Растения высажены рядами шириной 50 см, расстояние между рядами 70 см. С помощью визуального осмотра были отобраны 25 здоровых растений и 25 растений, имеющих видимые симптомы поражения белой пятнистостью (*Ramularia Tulasnei* Sacc). Отобранные растения были помечены стикерами желтого и красного цвета соответственно (рис. 1).

Получение изображений. Съемка осуществлялась с помощью квадрокоптера *DJI Phantom 4 Multispectral* (SZ DJI Technology Co., КНР). Установленная на дроне камера имеет шесть 1/2,9-дюймовых матриц CMOS, включая одну матрицу видимого излучения RGB и пять монохромных для формирования мультиспектральных изображений (табл. 1).

Съемка была проведена 05.07.2024 г. при ясной погоде на высоте 5,2 м. Разрешение съемки составило 0,3 см/пиксель. В результате получено 2328



Рис. 1. Листья земляники, пораженные белой пятнистостью

Fig. 1. Strawberry leaves affected by white leaf spot disease

снимков с перекрытием 75% в продольном и 60% в поперечном направлении.

Обработка изображений. Первым этапом обработки была сборка единого изображения (ортофотоплана) опытного участка из набора мультиспектральных снимков, полученных с помощью РМ4. Для данной цели использовалась программа *Agisoft Metashape Pro* (производитель *Agisoft LLC*, Россия) [19]. Результирующее изображение опытного участка было сформировано в формате *geoTiff* с разрешением 16 000×17 000×5 (рис. 2) размером 2,7 Гб.

Далее на полученном ортофотоплане вручную были выделены области интереса (*ROI*) размером 65×65 пикселей, содержащие помеченные стикерами больные и здоровые растения. Из каждой выделенной области был сформирован отдельный файл изображения. С целью удаления фона на изображения были наложены маски, построенные по пороговому значению индекса *NDVI*. Выделение *ROI*, удаление фона и формирование изображений выполнялось в программе *ENVI 5.2* (*ITT Visual Information Solutions*).

Таблица 1	
КРАТКИЕ ХАРАКТЕРИСТИКИ DJI PHANTOM 4 MULTISPECTRAL	
KEY SPECIFICATIONS OF THE DJI PHANTOM 4 MULTISPECTRAL	
Характеристика	Значение
Фильтры камеры, нм	Синий (blue): 450 ±16 Зеленый (green): 560±16 Красный (red): 650 ±16 Красный край (rededge): 730±16 Ближний инфракрасный (NIR): 840±26
Линзы	Угол обзора 62,7° Фокусное расстояние 5,74 мм
Максимальное разрешение изображения	1600×1300 (4:3,25)
Размер по земной поверхности	(H/18,9) см/пиксель H – высота дрона по отношению к картографируемому участку, м
Спутниковые системы позиционирования	GPS + BeiDou + Галилео
Взлетная масса дрона, г	1487
Максимальное время полета, мин	Около 27
Максимальная скорость, км/ч	50



Рис. 2. Ортофотоплан экспериментального участка
Fig. 2. Orthophoto map of the experimental plot

Наборы признаков и методы моделирования. Для анализа и классификации изображений нами был использован алгоритм случайного леса (*Random Forest*). Это нелинейная модель машинного обучения, основанная на использовании ансамбля решающих деревьев [20]. В качестве набора признаков для построения модели были рассмотрены три различных варианта:

- коэффициенты отражения в пяти диапазонах длин волн;

- 10 вегетационных индексов;
- 8 текстурных характеристик.

Все три набора признаков были сформированы из 50 файлов размера 65×65 с наложенными масками фона.

Первый набор данных включал коэффициенты отражения для каждого пикселя исходных изображений (174 800 пикс) на 5 длинах волн (синий 450 нм, зеленый 560 нм, красный 650 нм, красный край 730 нм, ближний инфракрасный 840 нм).

Второй набор данных представлял собой значения 10 вегетационных индексов, рассчитанных для каждого пикселя по формулам (табл. 2).

Третий набор данных содержал текстурные характеристики, вычисленные на основе матрицы совместной встречаемости уровней серого (*GLCM*) для каждого пикселя, для каждого мультиспектрального канала.

Было рассчитано восемь характеристик:

- среднее (*MEA*), отражающее средний уровень серого всех пикселей в матрице;
- дисперсия (*VAR*), описывающая разброс значений вокруг среднего;
- гомогенность (*HOM*), вычисляющая однородность матрицы;

- контраст (*CON*), представляющий локальную вариацию в матрице;

- несходство (*DIS*), отражающее разницу в оттенках серого;

- энтропия (*ENT*), выражающая уровень беспорядка в матрице;

- второй момент (*SEC*), который представляет однородность оттенков серого;

- корреляция (*COR*), измеряющая линейные зависимости пикселей.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Спектральные характеристики образцов. Усредненные значения коэффициентов отражения здоровых и пораженных грибными болезнями листьев земляники в различных спектральных диапазонах представлены на рисунке 3.




Рис. 3. Средние коэффициенты отражения здоровых и пораженных грибными болезнями листьев земляники
Fig. 3. Average reflectance coefficients of healthy and fungus-infected strawberry leaves

Из графика видно, что во всех диапазонах длин волн здоровые растения имеют более высокие коэффициенты отражения, чем больные. Общей чертой спектральных характеристик растительной ткани является более низкий коэффициент отражения в видимом

Таблица 2		Table 2
ВЕГЕТАЦИОННЫЕ ИНДЕКСЫ, ИСПОЛЬЗОВАННЫЕ В КАЧЕСТВЕ ПРИЗНАКОВ / VEGETATION INDICES USED AS CLASSIFICATION FEATURES		
Индекс	Формула для расчета	Биофизический индикатор
NDVI (Normalized Difference Vegetation Index)	$(NIR - Red)/(NIR + Red)$	Содержание антоцианинов
GRVI (Green-Red Vegetation Index)	$(Green - Red)/(Green + Red)$	
GNDVI (Green Normalized Difference Vegetation Index)	$(NIR - Green)/(NIR + Green)$	
RGI (Red Green Index)	$Red/Green$	Содержание антоцианинов
MACI (Modified Anthocyanin Content Index)	$NIR/Green$	
ACI (Anthocyanin Content Index)	$Green/NIR$	
NPCI (Normalized Pigment Chlorophyll Index)	$(Red\ Edge - Blue)/(Red\ Edge + Blue)$	Содержание хлорофилла
NDRE (Normalized Difference Red Edge Index)	$(NIR - Red\ Edge)/(NIR + Red\ Edge)$	
REGI (Red Edge Green Index)	$(Red\ Edge - Green)/(Red\ Edge + Green)$	Обнаружение стресса
RERI (Red Edge Rouge Index)	$(Red\ Edge - Red)/(Red\ Edge + Red)$	

диапазоне длин волн по сравнению с ближним инфракрасным диапазоном. На длине волны 650 нм (красный диапазон) наблюдается снижение коэффициента отражения, что связано с сильным поглощением света хлорофиллом в листьях. В диапазоне 730 нм (красный край) отражательная способность листьев резко возрастает по причине рассеивания света в межклеточном пространстве. В диапазоне 840 нм (ближний инфракрасный) коэффициент отражения остается высоким.

Критерий Стьюдента выявил значимость различий средних значений коэффициентов отражения меж-

ду больными и здоровыми растениями для каждой из длин волн с уровнем значимости $p < 0,001$ (табл. 3).

Расчет вегетационных индексов. 10 вегетационных индексов были рассчитаны по соответствующим формулам. Для каждого индекса был применен критерий Стьюдента с целью выявления значимости различий между здоровыми и больными растениями по значению индекса (табл. 4).

Индексы *NDVI*, *GRVI*, *NDRE*, *REGI*, *RERI*, *RGI*, *MACI* имели уровень значимости $p < 0,001$. Индекс *NPCI* имел уровень значимости $p < 0,05$. Индексы

Таблица 3

Table 3

РЕЗУЛЬТАТЫ ПРИМЕНЕНИЯ КРИТЕРИЯ СТЬЮДЕНТА К РАЗНИЦЕ СРЕДНИХ ЗНАЧЕНИЙ КОЭФФИЦИЕНТОВ ОТРАЖЕНИЯ МЕЖДУ БОЛЬНЫМИ И ЗДОРОВЫМИ РАСТЕНИЯМИ
STUDENT'S T-TEST RESULTS FOR DIFFERENCES IN THE MEAN REFLECTANCE VALUES BETWEEN DISEASED AND HEALTHY PLANTS

Диапазон длин волн	Разница средних	t-значение	p-значение
Blue	2871,18	54,82	< 0,001
Green	3052,23	45,21	< 0,001
Red	394,51	11,25	< 0,001
RedEdge	3738,41	56,21	< 0,001
NIR	4660,96	77,96	< 0,001

Примечание. Число степени свободы во всех случаях составляла 174 800.

Таблица 4

Table 4

РЕЗУЛЬТАТЫ ПРИМЕНЕНИЯ КРИТЕРИЯ СТЬЮДЕНТА К РАЗНИЦЕ СРЕДНИХ ЗНАЧЕНИЙ ВЕГЕТАЦИОННЫХ ИНДЕКСОВ МЕЖДУ БОЛЬНЫМИ И ЗДОРОВЫМИ РАСТЕНИЯМИ
STUDENT'S T-TEST RESULTS FOR DIFFERENCES IN MEAN VEGETATION INDEX VALUES BETWEEN DISEASED AND HEALTHY PLANTS

Вегетационный индекс	Разница средних	t-значение	p-значение
NDVI	0,034	51,30	< 0,001
GRVI	0,042	64,65	< 0,001
GNDVI	-0,001	-1,55	0,120
NPCI	-0,002	-2,00	0,046
NDRE	0,006	14,79	< 0,001
REGI	-0,006	-7,75	< 0,001
RERI	0,031	44,69	< 0,001
RGI	-0,056	-60,89	< 0,001
MACI	-0,021	-7,10	< 0,001
ACI	-0,002	-1,89	0,059

Примечание. Число степени свободы во всех случаях составляла 175 003.

Таблица 5

Table 5

РЕЗУЛЬТАТЫ ПРИМЕНЕНИЯ КРИТЕРИЯ СТЬЮДЕНТА К РАЗНИЦЕ СРЕДНИХ ЗНАЧЕНИЙ ТЕКСТУРНЫХ ХАРАКТЕРИСТИК МЕЖДУ БОЛЬНЫМИ И ЗДОРОВЫМИ РАСТЕНИЯМИ
STUDENT'S T-TEST RESULTS FOR DIFFERENCES IN MEAN TEXTURAL FEATURE VALUES BETWEEN DISEASED AND HEALTHY PLANTS

Текстурная характеристика	p-Значение критерия Стьюдента для диапазона длин волн				
	Blue	Green	Red	RedEdge	NIR
MEA	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
VAR	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
HOM	0,125	< 0,001	< 0,001	< 0,001	< 0,001
CON	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
DIS	< 0,001	< 0,001	< 0,001	0,544	< 0,001
ENT	0,998	< 0,001	< 0,001	< 0,001	< 0,001
SEC	0,949	< 0,001	< 0,001	< 0,001	< 0,001
COR	0,145	< 0,001	< 0,001	0,016	0,561

Таблица 6			Table 6
МАТРИЦЫ ОШИБОК КЛАССИФИКАЦИИ ДЛЯ РАЗЛИЧНЫХ НАБОРОВ ПРИЗНАКОВ CONFUSION MATRICES CORRESPONDING TO DIFFERENT FEATURE SETS			
Результат классификации	Реальные данные, %		Общая точность классификации, %
	здоровые	больные	
Спектр отражения			66,78
Здоровые объекты	65	32	–
Больные объекты	35	68	–
Вегетационные индексы			60,98
Здоровые объекты	64	42	–
Больные объекты	36	58	–
Текстурные характеристики			76,86
Здоровые объекты	76	22	–
Больные объекты	24	78	–

GNDVI, *ACI* имели незначимые различия средних значений.

Расчет текстурных характеристик. Для каждого из пяти спектральных каналов были рассчитаны 8 текстурных характеристик на основе матрицы совместной встречаемости уровней серого *GLCM*. Относительное расстояние, измеренное в пикселях в *GLCM* ($d = 1$), а относительная ориентация (θ) была средним значением четырех направлений ($\theta = 0, 45, 90$ и 135°).

С помощью критерия Стьюдента был определен набор характеристик для дальнейшего построения модели машинного обучения (табл. 5).

Из первоначального набора 40 характеристик 9 были исключены: корреляции (*COR*) для всех длин волн; гомогенность (*HOM*), энтропия (*ENT*), второй момент (*SEC*) для первого (*Green*) диапазона; несходство (*DIS*) для пятого (*NIR*) диапазона.

Построение моделей машинного обучения. Для анализа и классификации изображений нами была

использована модель машинного обучения *Random Forest*. В качестве признаков для построения модели были использованы три различных набора данных: коэффициенты отражения на 5 спектральных каналах; 10 вегетационных индексов; 31 текстурная характеристика. Исходные данные были разделены на обучающую и тестовую выборки в пропорциях 80 и 20% соответственно.

В качестве метрики оценки качества моделей использовалась общая точность классификации (*overall accuracy*), вычисляемая как процент отношения правильно классифицированных объектов к общему числу объектов. Результаты классификации приведены в таблице 6.

Классификация и картографирование изображений. Обученная на основе текстурных характеристик модель была применена для построения карты распространения грибных болезней земляники на экспериментальном поле. На рисунках 4, 5 представлены примеры классификации изображений в различных масштабах.




Рис. 4. Классификация изображений 65×65 пикселей методом *Random Forest* на основе текстурных характеристик: A1, A2 – растения, пораженные белой пятнистостью и их классификация; B1, B2 – здоровые растения и их классификация

Fig. 4. Classification of 65×65 pixel images using the *Random Forest* method based on texture features: A1, A2 – plants affected by white leaf spot disease and their classification results; B1, B2 – healthy plants and their classification results




Рис. 5. Классификация ортофотоплана методом *Random Forest* на основе текстурных характеристик

Fig. 5. Classification of the orthophotomap using the *Random Forest* method based on texture features

Выводы. На основе экспериментальных данных проведен анализ возможности обнаружения грибных болезней земляники садовой в полевых условиях с применением мультиспектральных сенсоров и беспилотных летательных аппаратов. Для дифференциации здоровых и пораженных белой пятнистостью растений был использован алгоритм машинного обучения *Random Forest*.

Полученные результаты позволяют сделать выводы, что модели, построенные на спектре отражения или на наборе вегетационных индексов, имеют слишком низкую точность классификации, не достаточную для обнаружения заболеваний земляники. Использование текстурных характеристик позволяет повысить точность модели до 77%, что, однако, также является низким показателем. Возможная причина недостаточной точности следующая.

Видимыми симптомами грибных болезней земляники являются цветные пятна на листьях растений. Размер пятен слишком мелкий, чтобы повлиять на средний спектр всего растения. Большая часть листа остается зеленого цвета. Тем не менее, при наличии пятен все растение считается заболевшим, и все пиксели данного растения классифици-

руются, как больные, в обучающей выборке. Этим объясняется и низкая точность моделей, построенных только на спектре или вегетационных индексах, и более высокая точность модели, учитывающей текстуру листьев, т.е. пространственное распределение цвета.

Предлагаемые пути улучшения точности моделей:

- использование сенсора с высоким разрешением при съемке, позволяющего классифицировать попиксельно больные и здоровые области листьев земляники;
- построение модели с использованием сверточной нейронной сети, учитывающей наряду со спектральными характеристиками, такие текстурные характеристики, как форма и взаимное расположение пятен на листьях.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Weiss M., Jacob F., Duveiller G. Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*. 2020. Vol. 236. N111402. DOI: 10.1016/j.rse.2019.111402.
2. Singh A., Jones S., Ganapathysubramanian B. et al. Challenges and opportunities in machine-augmented plant stress phenotyping. *Trends in Plant Science*. 2021. Vol. 26. N1. 53-69. DOI: 10.1016/j.rse.2019.111402.
3. Oerke E.-C. Remote Sensing of Diseases. *Annu. Rev. Phytopathol.* 2020. Vol. 58. 225–252. DOI: 10.1146/annurev-phyto-010820-012832.
4. Bock C.H., Barbedo J.G.A., Del Ponte E.M. et al. From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy. *Phytopathology Research*. 2020. Vol. 2. N9. DOI: 10.1186/s42483-020-00049-8.
5. Чешкова А.Ф. Обзор современных методов обнаружения и идентификации болезней растений на основе анализа гиперспектральных изображений // *Вавиловский журнал генетики и селекции*. 2022. Т. 26. N2. С. 202-213. DOI: 10.18699/VJGB-22-25.
6. Yang G., Liu J., Zhao C. et al. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: current status and perspectives. *Front. Plant Sci.* 2017. Vol. 8. N1111. DOI: 10.3389/fpls.2017.01111.
7. Курбанов Р.К., Ценч Ю.С., Захарова Н.И. Основные тенденции в развитии технологии аэрофотосъемки сельскохозяйственных угодий // *Сельскохозяйственные машины и технологии*. 2025. Т. 19. N1. С. 86-96. DOI: 10.22314/2073-7599-2025-19-1-86-95.
8. Кутырёв А.И., Хорт Д.О., Филиппов Р.А., Ценч Ю.С. Магнитно-импульсная обработка семян земляники садовой // *Сельскохозяйственные машины и технологии*. 2017. N5. С. 9-15. DOI: 10.22314/2073-7599-2017-5-9-15.
9. Nagaraju M., Chawla P. Systematic review of deep learning techniques in plant disease detection. *Int J Syst Assur Eng Manag.* 2020. Vol. 11. N3. 547–560. DOI: 10.1007/s13198-020-00972-1.
10. Benos L., Tagarakis A., Dolias G. et al. Machine learning in agriculture: a comprehensive updated review. *Sensors*. 2021. Vol. 21. N3758. DOI: 10.3390/s21113758.
11. Lan Y., Huang Z., Deng X. Comparison of machine learning methods for citrus greening detection on UAV multispectral images. *Computers and Electronics in Agriculture*. 2020. Vol. 171. N105234. DOI: 10.1016/j.compag.2020.105234.
12. Albetis J., Jacquin A., Goulard M. et al. On the potentiality of UAV multispectral imagery to detect *Flaves cencedorée* and grapevine trunk diseases. *Remote Sens.* 2019. Vol. 11. N23. DOI: 10.3390/rs11010023.
13. Ценч Ю.С., Курбанов Р.К., Захарова Н.И. Развитие систем управления полетом и средств аэрофотосъемки беспилотных воздушных судов сельскохозяйственного назначения // *Сельскохозяйственные машины и технологии*. 2024. Т. 18. N2. С. 11-19. DOI: 10.22314/2073-7599-2024-18-2-11-19.
14. Li S., Yuan F., Ata-UI-Karim S.T. et al. Combining color indices and textures of UAV-based digital imagery for rice LAI estimation. *Remote Sens.* 2019. Vol. 11. N1763. DOI: 10.3390/rs11151763.
15. Guo A., Huang W., Dong Y. et al. Wheat yellow rust detection using UAV-based hyperspectral technology. *Remote Sens.* 2021. Vol. 13. N123. DOI: 10.3390/rs13010123.
16. Cockerton H.M., Li B., Vickerstaff R.J. et al. Identifying *Verticillium dahlia* resistance in strawberry through disease screening of multiple populations and image based phenotyping. *Front. Plant Sci.* 2019. Vol. 10. N924. DOI: 10.3389/fpls.2019.00924.
17. Liao K., Yang F., Dang H. et al. Detection of eucalyptus leaf disease with UAV multispectral imagery. *Forests*. 2022. Vol. 13. N1322. DOI: 10.3390/f13081322.
18. Zhang S., Li X., Ba Y. et al. Banana Fusarium wilt disease detection by supervised and unsupervised methods from UAV-based multispectral imagery. *Remote Sens.* 2022. Vol. 14. N1231. DOI: 10.3390/rs14051231.
19. Sakamoto T., Ogawa D., Hiura S., Iwasaki N. Alternative procedure to improve the positioning accuracy of orthomosaic images acquired with agisoftmetashape and DJI p4 Multispectral for crop growth observation. *Photogrammetric Engineering & Remote Sensing*. 2022. Vol. 88. N5. 323–332. DOI: 10.14358/PERS.21-00064R2.
20. Belgiu M., Dragut L. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogram.* 2016. Vol. 114. N24–31. DOI: 10.1016/j.isprsjprs.2016.01.011.

REFERENCES

- Weiss M., Jacob F., Duveiller G. Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*. 2020. Vol. 236. N111402 (In English). DOI: 10.1016/j.rse.2019.111402.
- Singh A., Jones S., Ganapathysubramanian B. et al. Challenges and opportunities in machine-augmented plant stress phenotyping. *Trends in Plant Science*. 2021. Vol. 26. N1. 53-69 (In English). DOI: 10.1016/j.rse.2019.111402.
- Oerke E.-C. Remote sensing of diseases. *Annu. Rev. Phytopathol.* 2020. Vol. 58. N225–252 (In English). DOI: 10.1146/annurev-phyto-010820-012832.
- Bock C.H., Barbedo J.G.A., Del Ponte E.M. et al. From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy. *Phytopathology Research*. 2020. Vol. 2. N9 (In English). DOI: 10.1186/s42483-020-00049-8.
- Cheshkova A.F. A review of hyperspectral image analysis techniques for plant disease detection and identification. *Vavilov Journal of Genetics and Breeding*. 2022. Vol. 26. N2. 202-213 (In English). DOI: 10.18699/VJGB-22-25.
- Yang G., Liu J., Zhao C. et al. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: current status and perspectives. *Front. Plant Sci.* 2017. Vol. 8. N1111 (In English). DOI: 10.3389/fpls.2017.01111.
- Kurbanov R.K., Tsench Yu.S., Zakhharova N.I. Major Trends in the Development of Aerial Photography Technology for Agricultural Lands. *Agricultural Machinery and Technologies*. 2025. Vol. 19. N1. 86-96 (In Russian). DOI: 10.22314/2073-7599-2025-19-1-86-95.
- Kutyrev A.I., Khort D.O., Filippov R.A., Tsench Yu.S. Magnetic-pulse treatment of garden strawberry seeds. *Agricultural Machinery and Technologies*. 2017. N5. 9-15. (In Russian). DOI: 10.22314/2073-7599-2017-5-9-15.
- Nagaraju M., Chawla P. Systematic review of deep learning techniques in plant disease detection. *Int J Syst Assur Eng. Manag.* 2020. Vol. 11. N3. 547-560 (In English). DOI: 10.1007/s13198-020-00972-1.
- Benos L., Tagarakis A., Dolias G. et al. Machine learning in agriculture: a comprehensive updated review. *Sensors*. 2021. Vol. 21. N3758 (In English). DOI: 10.3390/s21113758.
- Lan Y., Huang Z., Deng X. et al. Comparison of machine learning methods for citrus greening detection on UAV multispectral images. *Computers and Electronics in Agriculture*. 2020. Vol. 171. N105234 (In English). DOI: 10.1016/j.compag.2020.105234.
- Albetis J., Jacquin A., Goulard M. et al. On the potentiality of uav multispectral imagery to detect *Flaves cencedorée* and grapevine trunk diseases. *Remote Sens.* 2019. Vol. 11. N23 (In English). DOI: 0.3390/rs11010023.
- Tsench Yu.S., Kurbanov R.K., Zakhharova N.I. Evolution of flight control systems and aerial photography in unmanned agricultural aircraft. *Agricultural Machinery and Technologies*. 2024. Vol. 18. N2. 11-19. (In Russian). DOI: 10.22314/2073-7599-2024-18-2-11-19.
- Li S., Yuan F., Ata-UI-Karim S.T. et al. Combining color indices and textures of UAV-based digital imagery for rice LAI estimation. *Remote Sens.* 2019. Vol. 11. N1763 (In English). DOI: 10.3390/rs11151763.
- Guo A., Huang W., Dong Y. et al. Wheat yellow rust detection using UAV-based hyperspectral technology. *Remote Sens.* 2021. Vol. 13. N123 (In English). DOI: 10.3390/rs13010123.
- Cockerton H.M., Li B., Vickerstaff R.J. et al. Identifying *Verticillium dahlia* resistance in strawberry through disease screening of multiple populations and image based phenotyping. *Front. Plant Sci.* 2019. Vol. 10. N924 (In English). DOI: 10.3389/fpls.2019.00924.
- Liao K., Yang F., Dang H. et al. Detection of eucalyptus leaf disease with UAV multispectral imagery. *Forests* 2022. Vol. 13. N1322 (In English). DOI: 10.3390/f13081322.
- Zhang S., Li X., Ba Y. et al. Banana *Fusarium* wilt disease detection by supervised and unsupervised methods from UAV-based multispectral imagery. *Remote Sens.* 2022. Vol. 14. N1231 (In English). DOI: 10.3390/rs14051231.
- Sakamoto T., Ogawa D., Hiura S., Iwasaki N. Alternative procedure to improve the positioning accuracy of orthomosaic images acquired with Agisoft Metashape and DJI P4 Multispectral for crop growth observation. *Photogrammetric Engineering & Remote Sensing*. 2022. Vol. 88. N5. 323-332 (In English). DOI: 10.14358/PERS.21-00064R2.
- Belgiu M., Dragut L. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* 2016. Vol. 114. N24–31 (In English). DOI: 10.1016/j.isprsjprs.2016.01.011.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Заявленный вклад соавторов:

Чешкова А.Ф. – постановка проблемы, анализ литературных источников, обработка и анализ экспериментальных данных, выбор и обучение модели, формирование выводов, работа с текстом статьи;

Риксен В.С. – научное консультирование, проведение эксперимента.

Авторы прочитали и одобрили окончательный вариант рукописи.

Conflict of interest

The authors declare no conflict of interest.

Coauthors' contribution:

Cheshkova A.F. – problem statement, literature review, experimental data processing and analysis, model selection and training, drawing conclusions, and drafting the article manuscript;

Riksen V.S. – scientific consultation and experimental work.

The authors read and approved the final manuscript.

Статья поступила в редакцию

Статья принята к публикации

The paper was submitted to the Editorial Office on

The paper was accepted for publication on

03.04.2025

20.05.2025