



Методы глубокого обучения и технологии БПЛА для идентификации заболеваний сельскохозяйственных растений

Салават Гумерович Мударисов,
д-р техн. наук, профессор, член-корреспондент
Академии наук Республики Башкортостан,
e-mail: salavam@gmail.com;

Ильнур Ринатович Мифтахов,
аспирант,
e-mail: info323@bk.ru

Башкирский государственный аграрный университет, г. Уфа, Российская Федерация

Реферат. Отметим, что при использовании технологий дистанционного зондирования и алгоритмов глубокого обучения значительно улучшаются возможности диагностики заболеваний растений на основе аэрофотоснимков. Работа посвящена анализу методов глубокого обучения и беспилотных летательных аппаратов для идентификации заболеваний сельскохозяйственных культур. (*Цель исследования*) Обобщение научных материалов по применению беспилотных летательных аппаратов, технологий дистанционного зондирования и методов глубокого обучения для раннего выявления и прогнозирования заболеваний культурных растений. (*Материалы и методы*) Представлены различные технологии с применением беспилотных летательных аппаратов и сенсоров для мониторинга состояния растений. Рассмотрены современные средства компьютерного зрения, направленные на повышение точности идентификации патологий растений. (*Результаты и обсуждение*) Выполнен анализ научных работ с 2010 по 2023 год. Основное внимание уделено сравнению эффективности различных алгоритмов глубокого обучения, таких как сверточные нейронные сети (CNN), с традиционными методами, включая метод опорных векторов (SVM), и классификаторы случайного леса. Показано, что алгоритмы глубокого обучения обеспечивают более точное и раннее выявление заболеваний, что делает их перспективными для применения в растениеводстве. Обозначили вызовы, связанные с применением беспилотных аппаратов, ограничения, обусловленные качеством данных, сложностью обработки больших объемов изображений и необходимостью разработки более совершенных моделей. Предложены пути преодоления этих проблем, в том числе оптимизация алгоритмов и улучшение методов предварительной обработки данных. (*Выводы*) Сочетание беспилотных летательных аппаратов и глубокого обучения открывает новые перспективы для повышения эффективности агропроизводства. Такие технологии позволяют точно диагностировать заболевания растений на ранних стадиях и прогнозировать их развитие, чтобы своевременно принимать меры по защите урожая. Интеграция интеллектуальных систем компьютерного зрения и беспилотной авиации является перспективным направлением, способным значительно улучшить методы мониторинга и управления здоровьем растений.

Ключевые слова: болезни растений, идентификация, диагностика, искусственный интеллект, беспилотный летательный аппарат, компьютерное зрение, глубокое обучение, система точного земледелия.

■ **Для цитирования:** Мударисов С.Г., Мифтахов И.Р. Методы глубокого обучения и технологии БПЛА идентификации заболеваний сельскохозяйственных растений // *Сельскохозяйственные машины и технологии*. 2024. Т. 18. №4. С. 24-33. DOI: 10.22314/2073-7599-2024-18-4-24-33. EDN: IVXJHW.

Review article

Deep Learning Methods and UAV Technologies for Crop Disease Detection

Salavat G. Mudarisov,
Dr.Sc.(Eng.), professor, corresponding Member of the
Academy of Sciences of the Republic of Bashkortostan,
e-mail: salavam@gmail.com;

Ilnur R. Miftakhov,
graduate student,
e-mail: info323@bk.ru

Bashkir State Agrarian University, Ufa, Russian Federation

Abstract. The paper underscores the significant advancements in plant disease diagnostics achieved through the integration of remote sensing technologies and deep learning algorithms, particularly in aerial imagery interpretation. It focuses on evaluating deep learning techniques and unmanned aerial vehicles for crop disease detection. (*Research purpose*) The study aims to review and systemize scientific literature on the application of unmanned aerial vehicles, remote sensing technologies and deep learning

methods for the early detection and prediction of crop diseases. (*Materials and methods*) The paper presents various technologies employing unmanned aerial vehicles and sensors for monitoring plant condition, with an emphasis on modern computer vision tools designed to improve the accuracy of plant pathology identification. (*Results and discussion*) The analysis encompasses scientific publications from 2010 to 2023, with a primary focus on comparing the effectiveness of deep learning algorithms, such as convolutional neural networks (*CNN*), against traditional methods, including support vector machines (*SVMs*) and random forest classifiers. The findings demonstrate that deep learning algorithms offer more accurate and earlier detection of diseases, highlighting their potential for application in plant growing. The paper also addresses challenges associated with the use of unmanned aerial vehicles, such as data quality limitations, the complexity of processing large volumes of images, and the need for the development of more advanced models. The paper proposes solutions to these issues, including algorithm optimization and improved data preprocessing techniques. (*Conclusions*) The integration of unmanned aerial vehicles and deep learning provides new prospects for enhancing the efficiency of agricultural production. These technologies enable precise early-stage diagnosis of plant diseases and facilitate the prediction of their progression, allowing for timely implementation of crop protection measures. The combination of intelligent computer vision systems with unmanned aerial vehicles presents significant opportunities for advancing monitoring methods and improving plant health management.

Keywords: plant diseases, identification, diagnostics, artificial intelligence, unmanned aerial vehicle, computer vision, deep learning, precision farming system.

■ **For citation:** Mudarisov S.G., Miftakhov I.R. Deep learning methods and UAV technologies for crop disease detection. *Agricultural Machinery and Technologies*. 2024. Vol. 18. N4. 24-33 (In Russian). DOI: 10.22314/2073-7599-2024-18-4-24-33. EDN: IVXJHW.

Болезни растений представляют значительную угрозу и могут привести к потере до 40% урожая [1]. Для предотвращения развития патологий необходимо их раннее обнаружение. Традиционные методы визуального мониторинга ограничены в силу масштабов посевов, особенно на больших полях. В этом контексте технологии глубокого обучения и беспилотные летательные аппараты представляют эффективные решения для идентификации и лечения болезней растений [2].

БПЛА с интеллектуальными визуальными системами позволяют обнаруживать заболевания на ранних стадиях. Алгоритмы глубокого обучения и компьютерного зрения стали ключевыми инструментами для автоматического мониторинга заболеваний растений [3]. В последние десятилетия сельское хозяйство значительно изменилось благодаря внедрению интеллектуальных машин, Интернета вещей и сложных сенсорных устройств [4]. Эти технологии помогают оптимизировать использование ресурсов и преодолевать вызовы, связанные с ограниченностью ресурсов и изменением климата [5].

Для мониторинга заболеваний растений используют спутниковые, авиационные и наземные системы, а также беспилотные летательные аппараты (БПЛА). Спутниковые и авиационные технологии ограничены пространственным и временным разрешением, а также высокими затратами. Наземные системы покрывают небольшие площади и требуют много времени [6]. БПЛА с интеллектуальными системами могут стать эффективным и недорогим решением для обнаружения заболеваний растений при любых масштабах охвата.

Традиционные методы машинного обучения,

такие как *SVM* и случайного леса, имеют ограничения из-за необходимости ручного извлечения признаков, что снижает их результативность в сложных условиях [7]. Глубокие алгоритмы обучения, напротив, автоматизируют извлечение признаков и обеспечивают точные прогнозы в целях защиты растений [8]. С момента появления в 2012 г. *CNN* (свёрточные нейронные сети) признан одним из самых эффективных алгоритмов в области компьютерного зрения для распознавания и классификации заболеваний растений [9].

Использование БПЛА, компьютерного зрения и глубокого обучения для идентификации заболеваний растений представляет собой перспективное направление, требующее междисциплинарного подхода. Несмотря на несколько опубликованных обзорных статей по этой теме, большинство их авторов фокусируются на наземных платформах. Например, обсуждаются методы классификации заболеваний томатов по наземным изображениям, но игнорируются методы сегментации и обнаружения объектов. Другие исследователи [10] рассматривают возможности БПЛА, но не углубляются в методы глубокого обучения или использования БПЛА как основной платформы сбора данных.

Цель исследования. Обобщить научный материал по использованию беспилотных летательных аппаратов, технологий дистанционного зондирования, методов предварительной обработки информации и моделей компьютерного зрения на основе глубокого обучения для раннего выявления и прогнозирования болезней культурных растений.

Материалы и методы. Для обобщения существующей информации использовали методологию ис-

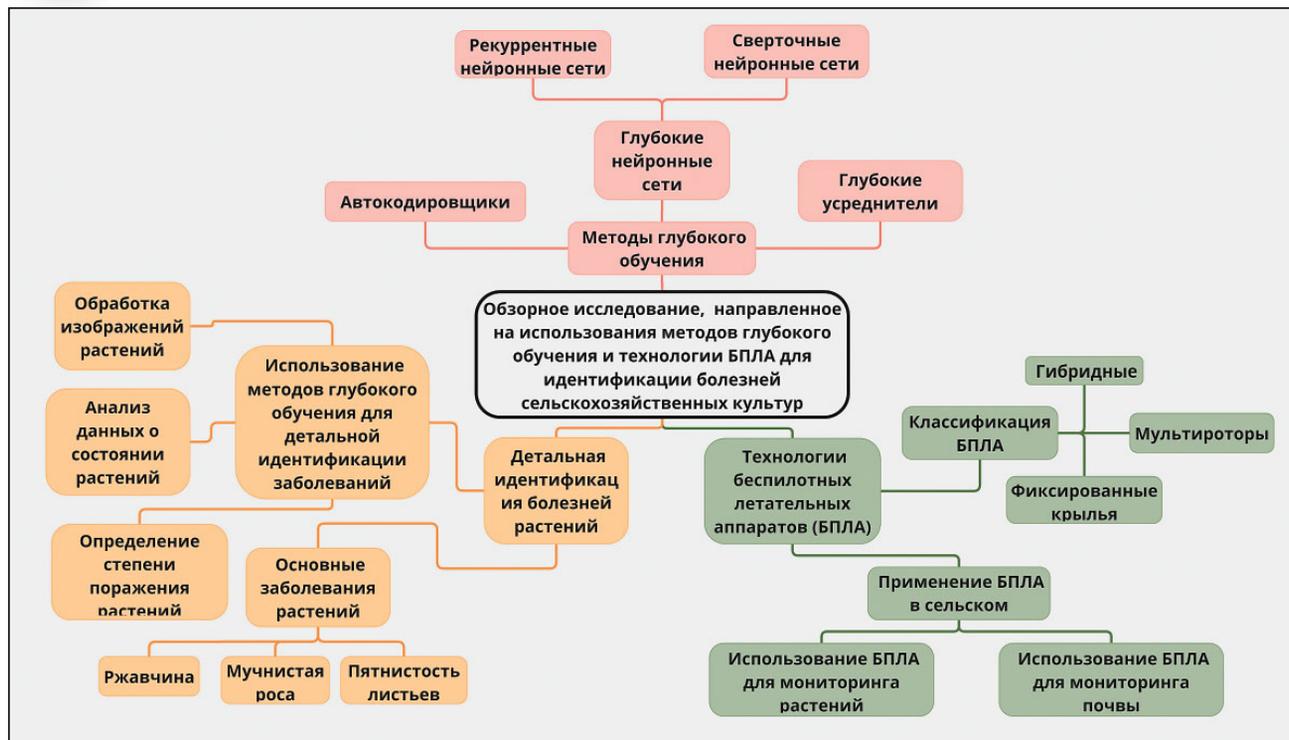


Рис. 1. Схема методологии исследования

Fig. 1. Research methodology diagram

следования с пошаговым отбором публикаций по применению алгоритмов глубокого обучения на основе компьютерного зрения для распознавания болезней растений БПЛА. Общий процесс методологии исследования представлен на *рисунке 1*.

Систематический обзор научных исследований проведен с использованием ключевых слов: [«болезни культурных растений» ИЛИ «болезни растений»] И [«обнаружение» ИЛИ «идентификация» ИЛИ «диагностика»] И [«БПЛА» ИЛИ «дрон»] И «искусственный интеллект» И «глубокое обучение» И «компьютерное зрение».

Основные задачи обзора:

- определение целевых растений и видов болезней;
- анализ типов БПЛА и сенсоров;
- оценка методов глубокого обучения для распознавания болезней;
- выявление модели с наилучшими результатами.

Поиск проводился в научных базах данных (*PubMed, ScienceDirect, MDPI, Springer, Web of Science*). Были собраны более 80 статей, связанных с распознаванием болезней растений на основе полученных БПЛА изображений, с использованием методов искусственного интеллекта (ИИ). Для дальнейшего анализа отобраны 56 наиболее релевантных публикаций.

Критерии отбора включали:

- временной интервал: публикации с 2010 по 2023 год, охватывающие период развития ИИ и БПЛА;
- экспортруемость в формат *.ris для использо-

вания в *VOSviewer*;

- содержание ключевых концепций, связанных с ИИ и БПЛА;
- ориентация на использование БПЛА и ИИ для сегментации и классификации данных.

Публикации анализировались с использованием *Mendeley Desktop v1.19.8*, после чего отбирались наиболее релевантные работы на основе аннотаций. Такой подход обеспечил высокое соответствие тематике исследований и позволил выделить часто встречающиеся ключевые термины: «глубокое обучение», «БПЛА», «заболевания растений» и «сверточная нейронная сеть», которые являются основными в контексте исследования.

Из 56 отобранных публикаций 40 включают хотя бы два из пяти проверенных ключевых слов с использованием *VOSviewer*. Это свидетельствует о том, что выбранные критерии отбора эффективно выделили существенные работы, сфокусированные на важных аспектах взаимодействия между глубоким обучением и заболеваниями растений, а также применения БПЛА.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ. БПЛА широко используются для решения таких задач, как поисково-спасательные операции, обнаружение лесных пожаров, мониторинг транспорта, точное земледелие, доставка посылок и развитие умных городов. В агропроизводстве применяются разные платформы сбора и анализа данных, в том числе спутники, самолеты и БПЛА. Спутники и самолеты способны охватывать большие площади, но требуют значительных затрат,



Мультироторный

Самолетный

Гибридный

Рис. 2. Типы сельскохозяйственных беспилотных летательных аппаратов

Fig. 2. Types of agricultural unmanned aerial vehicles

чувствительны к погодным условиям и обладают более низким разрешением изображений, что снижает их эффективность. В отличие от них, БПЛА, оснащенные камерами высокого пространственного и временного разрешения, более предпочтительный выбор для задач в растениеводстве, включая идентификацию болезней агрокультур.

В сельском хозяйстве используются три основные типы БПЛА: мультироторные, самолетного типа с фиксированными крыльями и гибридные БПЛА с вертикальными взлетом и посадкой (рис. 2).

Мультироторные БПЛА наиболее популярны благодаря гибкости, способности зависать, низкой высоте полета, доступу к труднодоступным местам, что позволяет выявлять ранние признаки болезней растений. Они классифицируются по количеству пропеллеров: трикоптеры (три пропеллера), квадрокоптеры (четыре), гексакоптеры (шесть) и октокоптеры (восемь). Гексакоптеры и октокоптеры могут поднимать тяжелые камеры, но отличаются высоким энергопотреблением [12]. Квадрокоптеры считаются оптимальными для мониторинга культур за счет гибкости и длительной выносливости [12]. Однако у них ограниченное время полета, малая грузоподъемность и высокое энергопотребление.

БПЛА самолетного типа обладают высокими скоростью и высотой полета и подходят для мониторинга обширных территорий [13]. Они характеризуются высокой грузоподъемностью, длительным полетом и большим покрытием площади. Однако они менее гибкие, не могут зависать в воздухе и для них требуется взлетно-посадочных полоса.

Гибридные БПЛА сочетают в себе преимущества обоих типов: вертикальный взлет и посадку с крейсерским полетом, преодолевая ограничения вертолетов и БПЛА самолетного типа [14]. Однако имеют высокую стоимость и не могут зависать. Их использование в мониторинге болезней культур пока ограничено.

Наиболее популярны, согласно литературным источникам, модели БПЛА китайской компании DJI (табл. 1).

Преимущества и недостатки сельскохозяйственных БПЛА различных типов приведены в таблице 2.

Выбор типа БПЛА для идентификации болезней растений зависит от размера полей: для малых и средних участков подходят вертолетные БПЛА, для больших – самолетные или гибридные. Важной характеристикой БПЛА является полезная нагрузка, включая камеры для дистанционного зондирования [23].

Тип камеры и БПЛА выбираются в зависимости от цели и типа обследуемой культуры. БПЛА самолетного и гибридного типа могут нести более сложные камеры, такие как гиперспектральные, более тяжелые и дорогие. Вертолетные БПЛА обеспечивают лучшее разрешение благодаря полету на низкой высоте.

Наиболее часто используемые камеры для мониторинга заболеваний культурных растений приведены в таблице 3. Среди популярных выделяют RGB-камеры благодаря низкой стоимости, простоте использования и высокому пространственному разрешению. Их часто используют для задач, связанных с визуальной идентификацией симптомов болезней растений, особенно на уровне листьев,

Таблица 1

Table 1

БПЛА, ИСПОЛЬЗУЕМЫЕ В СЕЛЬСКОХОЗЯЙСТВЕННОМ ПРОИЗВОДСТВЕ
UAVs USED IN AGRICULTURAL PRODUCTION

Тип, модель	Источник
<i>БПЛА мультироторного типа</i>	
Квадрокоптеры	
DJI Phantom 4 RTK	[15]
DJI Phantom 4 Pro	[16]
DJI Phantom 3 Professional	[17]
DJI Matrice 100	[18]
DJI S1000	[19]
3DR Iris (компания 3DRobotics, США)	[22]
Гексакоптеры	
DJI Matrice 600	[20]
DJI Matrice 600 Pro	[21]
<i>БПЛА самолетного типа</i>	
DT46 (компания Delair-Tech, Франция)	[13]

Таблица 2 Table 2	
ПРЕИМУЩЕСТВА И НЕДОСТАТКИ СЕЛЬСКОХОЗЯЙСТВЕННЫХ БПЛА ADVANTAGES AND DISADVANTAGES OF AGRICULTURAL UAVS	
Преимущества	Недостатки
<i>БПЛА мультиторного типа</i>	
Легкость управления и маневрирования	Ограниченное время полета
Возможность зависания в воздухе	Низкое покрытие площади
Взлет и посадка вертикальные	Малая грузоподъемность
Низкая стоимость	Высокое энергопотребление к труднодоступным местам
Доступность к труднодоступным местам	
<i>БПЛА самолетного типа</i>	
Высокая грузоподъемность	Высокая стоимость
Длительное время полета	Не могут зависать в воздухе
Большое покрытие площади	Трудность запуска и посадки
Высокая скорость	
Низкое энергопотребление	
<i>Гибридные</i>	
Длительное время полета	Не могут зависать в воздухе
Большое покрытие площади	Высокая стоимость
Высокая скорость	
Возможность вертикального взлета и посадки	
Относительно низкое энергопотребление	

что делает их удобными для небольших фермерских хозяйств.

Камеры типа *RGB* применялись во многих исследованиях, например, при распознавании болезней листьев сои использовали мультиспектральную камеру на БПЛА *DJI Phantom 4* [15] или для диагностики заболеваний кукурузы на ранних стадиях с камерой *4 RTK* [16]. Однако из-за чувствительности к окружающим условиям эти камеры не так эффективны для раннего обнаружения болезней, как мультиспектральные камеры.

Для более точной диагностики используют мультиспектральные камеры, позволяющие создавать карты вегетационных индексов (*NDVI*) [24], но у них более сложная калибровка и высокая стоимость. Предложен метод создания *NDVI*-карт с использованием данных *RGB*-камер с помощью генетических алгоритмов [15].

Спектральные изображения в зависимости от их разрешения можно разделить на два основных типа: мульти- и гиперспектральные. Они предоставляют информацию по электромагнитному спектру от видимого до ближнего инфракрасного (*NIR*), что позволяет вычислять надежные вегетационные индексы. Спектральные камеры широко используются для идентификации болезней растений и культур с БПЛА благодаря предоставлению более детальной информации, чем обычные камеры. Основные различия между мульти- и гиперспектральными системами изображения можно свести к двум: количество каналов в гиперспектральных камерах намного больше и они дороже.

Мультиспектральные и гиперспектральные камеры эффективнее как инструмент для автоматического обнаружения симптомов болезней и в сравнении с *RGB*-камерами надежнее при различных условиях освещения, что позволяет им более точно различать здоровые и стрессовые растения. Гиперспектральные камеры предоставляют более детальную информацию, позволяя классифицировать различные типы стресса культур, что труднее сделать по мультиспектральным данным [29].

Тепловизионные инфракрасные камеры – это еще один возможный тип сенсоров для идентификации болезней культур с помощью аэрофотосъемки. Инфракрасный (*IR*) датчик включает в себя несколько спектральных полос: в ближней инфракрасной (*NIR*), коротковолновой (*SWIR*), средневолновой (*MWIR*), длинноволновой (*LWIR*) и дальней инфракрасной (*FIR*) зонах [30, 31]. Эти камеры можно применять и днем, и ночью.

Таблица 3 Table 3						
КАМЕРЫ, ИСПОЛЪЗУЕМЫЕ ДЛЯ ИДЕНТИФИКАЦИИ БОЛЕЗНЕЙ РАСТЕНИЙ CAMERAS USED FOR PLANT DISEASE DETECTION						
Год	Культура	Модель БПЛА	Полезная нагрузка	Модель	Результат, %	Источник
2023	Кукуруза	<i>DJI Phantom 4 Pro</i>	<i>RGB</i>	<i>YOLOv5</i>	92,00	[16]
2023	Соя	<i>DJI Phantom 4 multispectral</i>	Мультиспектральная камера	<i>AlexNet</i>	99,07	[27]
2023	Пшеница	<i>DJI 4 pro</i>	<i>RGB</i>	<i>LSTM-PSPNet</i>	95,20	[20]
2022	Картофель	<i>DJI S1000</i>	Гиперспектральная камера	<i>3D-CNN</i>	98,09	[19]
2021	Пшеница	<i>DJI Matrice 100</i>	Мультиспектральная камера	<i>U-Net</i>	91,3	[28]
2021	Пшеница	<i>DJI Sentinel 2</i>	<i>RGB</i>	<i>PSPNet</i> <i>U-Net</i> <i>FCN</i>	98 94 90	[25]
2021	Пшеница	<i>DJI M100</i>	Мультиспектральная камера	<i>Ir-UNet</i>	94,63	[25]
2019	Пшеница	<i>DJI S1000</i>	<i>RGB</i>	<i>DCNN</i>	85,00	[26]
2018	Картофель	<i>3DR Iris + автопилот Pixhawk</i>	Мультиспектральная камера	<i>MLP (NIR-G-B)</i>	8,8	[22]

Установленные на БПЛА тепловизионные камеры используются для мониторинга водного стресса и болезней культур. В отличие от RGB-камер, которые фиксируют видимый свет, тепловизионные камеры чувствительны к инфракрасному спектру, предоставляя дополнительную информацию о состоянии растения, которую нельзя получить с помощью мульти- или гиперспектральных камер. Они генерируют карту тепловых точек по измерению излучения целевой культуры, а по энергии излучения можно оценивать состояние культуры на основе ее температурных аномалий и несоответствий. Данные термального дистанционного зондирования могут использоваться для обнаружения болезней культур до того, как они визуальными заметны. Однако, в случае тепловизионных изображений необходимо учитывать несколько факторов: временное и пространственное разрешение изображений, условия окружающей среды, разнообразие видов и стадий роста культур, а также высоту полета БПЛА и угол обзора [32].

Собранные с камер технического зрения данные необходимо обрабатывать и извлекать ключевые характеристики для идентификации болезней с использованием мощных алгоритмов и методов.

Предварительная обработка данных технического зрения играет ключевую роль в точной и эффективной идентификации болезней, может включать следующие действия.

1. Устранение и фильтрация шума с помощью различных методов, таких как медианный фильтр или фильтр Гаусса, помогает улучшить качество изображения и избавиться от случайных искажений.

2. Нормализация и масштабирование изображений (приведение яркости и контраста изображений к стандартным значениям) помогают унифицировать данные и обеспечивают согласованность в последующей обработке. В исследовании [30] отмечается, что размер входного изображения для различных архитектур CNN, таких как *U-net* и *InceptionNet* (1, 2 и 3), имеет важное значение и варьируется. Для модели *U-net* все изображения из обучающего набора данных были изменены до размера $256 \times 256 \times 3$, в то время как для *InceptionNet* используется размер изображений $299 \times 299 \times 3$. Это объясняется тем, что сети CNN устанавливают определенные требования к размеру входных изображений. Важным этапом исследования была нормализация изображений с использованием *z-score normalization*. Этот метод нормализации выполнялся на основе стандартного отклонения (*SD*) и среднего значения набора обучающих изображений. Такой подход позволяет стандартизировать данные и обеспечить их согласованность перед обучением модели.

Комплексный подход, объединяющий глубокое обучение с методами улучшения данных, является перспективным для точного выявления болезней растений и оценки их влияния на выживаемость.

3. Калибровка цвета (в случае цветных изображений) необходима для корректного анализа и может включать баланс белого и коррекцию цветового пространства.

4. Применение методов улучшения контраста, таких как гистограммное выравнивание, может повысить видимость деталей и облегчить выделение ключевых характеристик.

5. Применение операторов выделения границ, например, оператора Собеля или оператора Кэнни, позволяет выделить контуры и структуры, что важно для определения особенностей болезней.

6. Преобразование изображения в бинарное (черно-белое) с использованием порогового значения может облегчить последующий анализ и выделение объектов интереса.

7. Применение операций морфологии, таких как эрозия и дилатация, способствует устранению шумов, объединению близких объектов и улучшению их формы.

8. Использование специализированных алгоритмов для извлечения ключевых характеристик, таких как текстура, форма и размер, в зависимости от конкретной задачи.

После предварительной обработки данные будут готовы для более точного и надежного анализа с применением алгоритмов машинного обучения или других методов идентификации болезней.

За последнее десятилетие глубокие алгоритмы обучения на основе компьютерного зрения достигли интересных результатов во многих областях, включая сельское хозяйство. Поражение болезнями растения визуально проявляется такими симптомами, как изменение цвета, скручивание листьев, пятна на листьях и плодах. Это делает глубокие алгоритмы обучения лучшим выбором при идентификации болезней. Для этой цели можно использовать три основных задачи компьютерного зрения: обнаружение объектов [21], классификацию изображений и их сегментацию.

Диагностика болезней культур с использованием глубоких алгоритмов обучения на основе обработки изображений, полученных с помощью БПЛА, вызывает все больший интерес. Несколько последних исследований по обнаружению болезней культур с помощью БПЛА основаны на глубоких моделях обучения для преодоления ограничений традиционных методов, особенно алгоритмов свёрточных нейронных сетей. Эти исследования были направлены на болезни полевых и овощных культур: пшеницы [15], кукурузы [16], томаты и картофель [22].

В нескольких недавних исследованиях успешно использовались комбинация полученных с БПЛА

изображений и глубоких алгоритмов обучения для идентификации различных заболеваний основных злаковых культур, включая пшеницу и кукурузу. Например, авторы [15], а также [33] сосредоточились на выявлении болезни желтой ржавчины с использованием различных моделей компьютерного зрения на основе глубокого обучения. Это одна из самых опасных болезней, которая ежегодно приводит к значительным, более 5 млн т, потерям урожая пшеницы. Для минимизации воздействия этой болезни авторы [26] предложили новый метод семантической сегментации на основе модели *U-Net* для выявления зараженных участков пшеничных полей с использованием мультиспектральных данных, собранных с помощью платформы БПЛА. Для улучшения основной архитектуры *U-Net* они внедрили три модуля: нерегулярного кодирования (*Irregular Encoder Module, IEM*), нерегулярного декодирования (*Irregular Decoder Module, IDM*) и переоценки каналов с учетом содержания (*Content Aware Channel Re-weight Module, CCRM*). Исследовалось влияние типа входных данных на общую производительность глубокой модели обучения для обнаружения болезни желтой ржавчины в пшеничных полях. Было обнаружено, что предложенная модель *Ir-UNet* показывает хорошие результаты, используя всю информацию из пяти полос, собранную с мультиспектральной камеры *RedEdge*. Общая точность достигла 96,95%, а *F1*-мера — 94,66%, что превысило результаты, полученные в работе [27], где *F1*-мера составила 92%. Кроме того, немного улучшилась общая точность (96,97%) при комбинации всех исходных полос и их вариантов измеренных выбранных вегетационных индексов (*SVI*). Применяя переоценку признаков с использованием *CCRM* модель *Ir-Unet* обеспечивает общую точность 97,13%.

Аналогично, в работе [23] исследовали производительность различных моделей машинного обучения и глубокого обучения для выявления болезни желтой ржавчины в пшеничных полях на основе *RGB*-изображений, полученных с БПЛА. Выяснилось, что обеспечивают лучшую точность алгоритмы *PSPNet* (98%) и *SVM* (96%) среди всех протестированных моделей, включая *Random Forest* (73%), *BPNN* (86%), *FCN* (90%), и *U-Net* (94%).

Для определения степени тяжести поражения картофеля поздней мучнистой росой на мультиспектральных изображениях, полученных с помощью БПЛА [22], использовали различные методы, в том числе традиционные методы машинного обучения и модель глубокого обучения. Результаты показали, что *CNN* и *RF* превзошли *MLP* и *SVR*, достигнув значений R^2 соответственно 0,74 и 0,75. Аналогично авторы исследования [19] разработали *3D-CNN* модель под названием *CropdocNet* для

обнаружения болезни поздней мучнистой росы картофеля на гиперспектральных изображениях, полученных с помощью БПЛА; средняя точность на обучающем и независимом тестовом наборах достигла соответственно около 98 и 96%.

В целом сочетание глубокого обучения и изображений, полученных с помощью БПЛА, показало многообещающие результаты в идентификации и классификации различных заболеваний культур, способствуя внедрению и развитию системы точного земледелия.

Выводы. Современные технологии на базе беспилотных летательных аппаратов (БПЛА) и передовых алгоритмов глубокого обучения становятся новым эффективным решением для выявления, диагностики и прогнозирования болезней сельскохозяйственных растений.

Выбор типа БПЛА для решения задач идентификации болезней зависит в основном от площади возделываемых культур. Для малых и средних участков предпочтительны БПЛА вертолетного типа, обладающие легкостью управления и возможностью зависания в воздухе. Для больших площадей подходят БПЛА самолетного типа, которые характеризуются высокой грузоподъемностью, длительным полетом, высокой скоростью и низким энергопотреблением. Гибридные БПЛА объединяют преимущества обоих типов, обеспечивая длительность полета, большое покрытие площади и высокую скорость.

Для идентификации болезней растений наиболее распространенными типами датчиков являются *RGB*-камеры. Для получения более детальной информации и обнаружения различных типов стресса культурных растений предпочтительными являются гиперспектральные камеры. Улучшить возможности визуального обнаружения систем идентификации болезней позволяют тепловизионные инфракрасные камеры, с их помощью можно генерировать карту тепловых точек для оценки состояния культуры на основе ее температурных аномалий и несоответствий.

Для качественного и точного выявления болезней растений следует использовать алгоритмы глубокого обучения. Они обеспечивают более высокую производительность по сравнению с традиционными методами (основанными на пространственных и наземных технологиях), а также методами машинного обучения, такими как метод опорных векторов и классификаторы случайного леса.

Компьютерное зрение в связке с беспилотными летательными аппаратами открывает новые возможности диагностики заболеваний растений. БПЛА, оснащенные камерами и специализированным программным обеспечением, способны с большой точностью собирать изображения полей с целью анали-

за и классификации здоровых и пораженных участков растений. Обнаружение объектов помогает изолировать и идентифицировать конкретные признаки болезни, а методы сегментации изображений позволяют детально определить границы пора-

женных областей и оценить степень поражения. Эти технологии не только ускоряют процесс диагностики, снижая зависимость от визуальной оценки агрономами, но и предоставляют детальные данные для принятия решений о точечной обработке растений.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Thangaraj R., Anandamurugan S., Pandiyan P. et al. Artificial intelligence in tomato leaf disease detection: a comprehensive review and discussion. *Journal of Plant Diseases and Protection*. 2021. DOI: 10.1007/s41348-021-00500-8.
2. Курченко Н.Ю., Даус Ю.В., Труфляк Е.В., Ильченко Я.А. Параметры применения беспилотных летательных аппаратов при обработке средствами защиты растений сельскохозяйственных культур // *Известия Нижневолжского агроуниверситетского комплекса*. 2023. N1 (69). С. 527-536. DOI: 10.32786/2071-9485-2023-69-1-527-536.
3. Sladojevic S., Arsenovic M., Anderla A. et al. Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*. 2016. 1-11. DOI: 10.1155/2016/3289801.
4. Smirnov I., Kutuyev A., Khort D. et al. Developing neural-based hardware and software complex with a mobile application for monitoring apple fruits on tree canopy. *Horticulture and Viticulture*. 2023. 43-51. DOI: 10.31676/0235-2591-2023-1-43-51.
5. Neupane K., Baysal-Gurel F. Automatic identification and monitoring of plant diseases using Unmanned Aerial Vehicles: a review. *Remote Sensing*. 2021. Vol. 13. N19. 1-19. DOI: 10.3390/rs13193841.
6. Sankaran S., Khot L.R., Espinoza C.Z. et al. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. *European Journal of Agronomy*. 2015. Vol. 70. 112-123. DOI: 10.1016/j.eja.2015.07.004.
7. Rokach L., Maimon O. Top-down induction of decision trees classifiers – a survey. *IEEE Systems, Man, and Cybernetics*. 2005. Vol. 35. N4. 476-487. DOI: 10.1109/TSMCC.2004.843178.
8. Singh A., Ganapathysubramanian B. Machine learning for high-throughput stress phenotyping in plants. *Trends in Plant Science*. 2020. Vol. 25. N1. 11-13. DOI: 10.1016/j.tplants.2019.09.003.
9. Kamilaris A., Prenafeta-Boldú F.X. Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*. 2018. Vol. 147. 70-90. DOI: 10.1016/j.compag.2018.02.016.
10. Zhang H., Zhang B., Wei Z. et al. Lightweight integrated solution for a UAV-borne hyperspectral imaging system. *Remote Sensing*. 2020. Vol. 12. N4. 657-671. DOI: 10.3390/rs12040657.
11. Pittu V.R., Gorantla S.R. Diseased area recognition and pesticide spraying in farming lands by multicopters and image processing system. *Journal Européen des Systèmes Automatisés*. 2020. Vol. 53(1). 123-130. DOI: 10.18280/jesa.530115.
12. Kurbanov R., Litvinov M. Development of a gimbal for the Parrot Sequoia multispectral camera for the UAV DJI Phantom 4 Pro. *IOP Series*. 2020. 012062 (In English). DOI: 10.1088/1757-899X/1001/1/012062.
13. Albetis J., Jacquin A., Goulard M. et al. On the potentiality of UAV multispectral imagery to detect flavescence dorée and grapevine trunk diseases. *Remote Sensing*. 2019. Vol. 11. N1. 23-37. DOI: 10.3390/rs11010023.
14. Song B., Park K. Detection of aquatic plants using multispectral UAV imagery and vegetation index. *Remote Sensing*. 2020. 387-400. DOI: 10.3390/rs12030387.
15. Zhang T., Xu Z., Su J. et al. Ir-UNet: irregular segmentation u-shape network for wheat yellow rust detection by UAV multispectral imagery. *Remote Sensing*. 2021. Vol. 13. N19. 3892. DOI: 10.3390/rs13193892.
16. Sassu A., Motta J., Deidda A. et al. Artichoke deep learning detection network for site-specific agrochemicals UAS spraying. *Computers and Electronics in Agriculture*. 2023. Vol. 213. 106395. DOI: 10.1016/j.compag.2022.106395.
17. Kerkech M., Hafiane A., Canals R. Plant disease detection using the UAV imagery and deep learning. *Computers in Industry*. 2020. Vol. 123. 103316. DOI: 10.1016/j.compind.2020.103316.
18. Li J., Huang W., Zhao C., Jin J. UAV-based multispectral remote sensing for precision agriculture: A case study on wheat nitrogen and water stress. *International Journal of Remote Sensing*. 2019. Vol. 40(4). 1325-1346. DOI: 10.1080/01431161.2018.1525662.
19. Shi Y., Han L., Kleerekoper A. et al. Novel CropDocNet model for automated potato late blight disease detection from unmanned aerial vehicle-based hyperspectral imagery. *Remote Sensing*. 2022. 20396. DOI: 10.3390/rs14020396.
20. Yu J., Cheng T., Cai N. et al. Wheat lodging segmentation based on LSTM-PSPNet deep learning network. *Drones*. 2023. Vol. 7. N2. 53-66. DOI: 10.3390/drones7020053.
21. Xu W., Chen P., Zhan Y. et al. Cotton yield estimation model based on machine learning using time series UAV remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*. 2021. Vol. 104. 102511. DOI: 10.1016/j.jag.2021.102511.
22. Duarte-Carvajalino J.M., Alzate D.F., Ramirez A.A. et al. Evaluating late blight severity in potato crops using unmanned aerial vehicles and machine learning algorithms. *Remote Sensing*. 2018. Vol. 10. 1513. DOI: 10.3390/rs10101513.
23. Ценч Ю.С., Курбанов Р.К., Захарова Н.И. История развития 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.
24. Курбанов Р.К., Захарова Н.И., Захарова О.М., Горшков Д.М. Оценка перезимовки всходов селекционной озимой пшеницы с помощью БПЛА // *Инновации в сельском хозяйстве*. 2019. N3(32). С. 133-139. EDN: YYRCTL.
 25. Zhang X., Han L., Dong Y. et al. A deep learning-based approach for automated yellow rust disease detection from high-resolution hyperspectral UAV images. *Remote Sensing*. 2019. Vol. 11. N13. 1554. DOI: 10.3390/rs11131554.
 26. Zhang B., Zhao D. An ensemble learning model for detecting soybean seedling emergence in UAV imagery. *Sensors*. 2023. Vol. 23. N15. 6662. DOI: 10.3390/s23156662.
 27. Su J., Yi D., Su B. et al. Aerial visual perception in smart farming: Field study of wheat yellow rust monitoring. *IEEE Transactions on Industrial Informatics*. 2020. Vol. 17. N3. 2242-2249. DOI: 10.1109/TII.2020.2979237.
 28. Behmann J., Mahlein A.-K., Rumpf T. et al. A Review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture*. 2015. Vol. 16. N3. 239-260. DOI: 10.1007/s11119-014-9372-7.
 29. Mahlein A.-K., Kuska M.T., Behmann J. et al. Hyperspectral and thermal imaging of plant diseases in horticulture. *Sensors*. 2018. Vol. 18. N9. 2936. DOI: 10.3390/s18092936.
 30. Shahzaad B., Bouguettaya A., Mistry S. et al. Resilient composition of drone services for delivery. *Future Generation Computer Systems*. 2021. Vol. 115. 335-350. DOI: 10.1016/j.future.2020.09.023.
 31. Курбанов Р.К., Захарова Н.И., Гайдук О.М. Использование теплового канала (LWIR) для оценки состояния посевов и прогнозирования урожайности сельскохозяйственных культур // *Электротехнологии и электрооборудование в АПК*. 2020. Т. 67. N3(40). С. 87-94. DOI: 10.22314/2658-4859-2020-67-3-87-94.
 32. Лелюхин Д., Тутьгин В. Система диагностики заболеваний листьев растений по фотоизображениям, полученным с помощью БПЛА // *Известия Тульского государственного университета*. 2018. N2. С. 129-137. EDN: RAQZLK.
 33. Pan Q., Gao M., Wu P. et al. A deep-learning-based approach for wheat yellow rust disease recognition from unmanned aerial vehicle images. *Sensors*. 2021. 6540-6553. DOI: 10.3390/s21196540.

REFERENCES

1. Thangaraj R., Anandamurugan S., Pandiyan P. et al. Artificial intelligence in tomato leaf disease detection: a comprehensive review and discussion. *Journal of Plant Diseases and Protection*. 2021 (In English). DOI: 10.1007/s41348-021-00500-8.
2. Kurchenko N.Yu., Daus Yu.V., Truflyak E.V., Ilchenko Ya.A. Parameters of the use of unmanned aerial vehicles in the processing of crop protection products. *Proceedings of the Nizhnevolsky Agrouniversity Complex*. 2023. N1(69). 527-536 (In Russian). DOI: 10.32786/2071-9485-2023-69-1-527-536.
3. Sladojevic S., Arsenovic M., Anderla A. et al. Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*. 2016. 1-11 (In English). DOI: 10.1155/2016/3289801.
4. Smirnov I., Kuttyrev A., Khort D. et al. Developing neural-based hardware and software complex with a mobile application for monitoring apple fruits on tree canopy. *Horticulture and Viticulture*. 2023. 43-51 (In English). DOI: 10.31676/0235-2591-2023-1-43-51.
5. Neupane K., Baysal-Gurel F. Automatic identification and monitoring of plant diseases using Unmanned Aerial Vehicles: a review. *Remote Sensing*. 2021. Vol. 13. N19. 1-19 (In English). DOI: 10.3390/rs13193841.
6. Sankaran S., Khot L.R., Espinoza C.Z. et al. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. *European Journal of Agronomy*. 2015. Vol. 70. 112-123 (In English). DOI: 10.1016/j.eja.2015.07.004.
7. Rokach L., Maimon O. Top-down induction of decision trees classifiers – a survey. *IEEE Transactions on Systems, Man, and Cybernetics. Part C (Applications and Reviews)*. 2005. Vol. 35. N4. 476-487 (In English). DOI: 10.1109/TSMCC.2004.843178.
8. Singh A., Ganapathysubramanian B. Machine learning for high-throughput stress phenotyping in plants. *Trends in Plant Science*. 2020. Vol. 25. N1. 11-13 (In English). DOI: 10.1016/j.tplants.2019.09.003.
9. Kamilaris A., Prenafeta-Boldú F.X. Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*. 2018. Vol. 147. 70-90 (In English). DOI: 10.1016/j.compag.2018.02.016.
10. Zhang H., Zhang B., Wei Z. et al. Lightweight integrated solution for a UAV-borne hyperspectral imaging system. *Remote Sensing*. 2020. Vol. 12. N4. 657-671 (In English). DOI: 10.3390/rs12040657.
11. Pittu V.R., Gorantla S.R. Diseased area recognition and pesticide spraying in farming lands by multicopters and image processing system. *Journal Européen des Systèmes Automatisés*. 2020. Vol. 53(1). 123-130 (In English). DOI: 10.18280/jesa.530115.
12. Kurbanov R., Litvinov M. Development of a gimbal for the Parrot Sequoia multispectral camera for the UAV DJI Phantom 4 Pro. *IOP Conference Series*. 2020. 012062 (In English). DOI: 10.1088/1757-899X/1001/1/012062.
13. Albetis J., Jacquin A., Goulard M. et al. On the potentiality of UAV multispectral imagery to detect flavescence dorée and grapevine trunk diseases. *Remote Sensing*. 2019. Vol. 11. N1. 23-37 (In English). DOI: 10.3390/rs11010023.
14. Song B., Park K. Detection of aquatic plants using multispectral UAV imagery and vegetation index. *Remote Sensing*. 2020. 387-400 (In English). DOI: 10.3390/rs12030387.
15. Zhang T., Xu Z., Su J. et al. Ir-unet: Irregular segmentation u-shape network for wheat yellow rust detection by UAV

- multispectral imagery. *Remote Sensing*. 2021. Vol. 13. N19. 3892 (In English). DOI: 10.3390/rs13193892.
16. Sassu A., Motta J., Deidda A. et al. Artichoke deep learning detection network for site-specific agrochemicals UAS spraying. *Computers and Electronics in Agriculture*. 2023. Vol. 213. 106395 (In English). DOI: 10.1016/j.compag.2022.106395.
 17. Kerkech M., Hafiane A., Canals R. Plant disease detection using the UAV imagery and deep learning. *Computers in Industry*. 2020. Vol. 123. 103316 (In English). DOI: 10.1016/j.compind.2020.103316.
 18. Li J., Huang W., Zhao C., Jin J. UAV-based multispectral remote sensing for precision agriculture: A case study on wheat nitrogen and water stress. *International Journal of Remote Sensing*. 2019. Vol. 40(4). 1325-1346 (In English). DOI: 10.1080/01431161.2018.1525662.
 19. Shi Y., Han L., Kleerekoper A. et al. Novel CropdocNet model for automated potato late blight disease detection from unmanned aerial vehicle-based hyperspectral imagery. *Remote Sensing*. 2022. 20396 (In English). DOI: 10.3390/rs14020396.
 20. Yu J., Cheng T., Cai N. et al. Wheat lodging segmentation based on LSTM-PSPNet deep learning network. *Drones*. 2023. Vol. 7. N2. 53-66 (In English). DOI: 10.3390/drones7020053.
 21. Xu W., Chen P., Zhan Y. et al. Cotton yield estimation model based on machine learning using time series UAV remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*. 2021. Vol. 104. 102511 (In English). DOI: 10.1016/j.jag.2021.102511.
 22. Duarte-Carvajalino J.M., Alzate D.F., Ramirez A.A. et al. Evaluating late blight severity in potato crops using unmanned aerial vehicles and machine learning algorithms. *Remote Sensing*. 2018. Vol. 10. 1513 (In English). DOI: 10.3390/rs10101513.
 23. Tsench Yu.S., Kurbanov R.K., Zakharova 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.
 24. Kurbanov R.K., Zakharova N.I., Zakharova O.M., Gorshkov D.M. Assessment of seedlings breeding winter wheat after overwintering using UAVS. *Innovations in Agriculture*. 2019. N3(32). C. 133-139 (In Russian). EDN: YYRCTL.
 25. Zhang X., Han L., Dong Y. et al. A deep learning-based approach for automated yellow rust disease detection from high-resolution hyperspectral UAV images. *Remote Sensing*. 2019. Vol. 11. N13. 1554 (In English). DOI: 10.3390/rs11131554.
 26. Zhang B., Zhao D. An ensemble learning model for detecting soybean seedling emergence in UAV imagery. *Sensors*. 2023. Vol. 23. N15. 6662 (In English). DOI: 10.3390/s23156662.
 27. Su J., Yi D., Su B. et al. Aerial visual perception in smart farming: Field study of wheat yellow rust monitoring. *IEEE Transactions on Industrial Informatics*. 2020. Vol. 17. N3. 2242-2249 (In English). DOI: 10.1109/TII.2020.2979237.
 28. Behmann J., Mahlein A.-K., Rumpf T. et al. A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture*. 2015. Vol. 16. N3. 239-260 (In English). DOI: 10.1007/s11119-014-9372-7.
 29. Mahlein A.-K., Kuska M. T., Behmann J. et al. Hyperspectral and thermal imaging of plant diseases in horticulture. *Sensors*. 2018. Vol. 18. N9. 2936 (In English). DOI: 10.3390/s18092936.
 30. Shahzaad B., Bouguettaya A., Mistry S. et al. Resilient composition of drone services for delivery. *Future Generation Computer Systems*. 2021. Vol. 115. 335-350 (In English). DOI: 10.1016/j.future.2020.09.023.
 31. Kurbanov R.K., Zakharova N.I., Gayduk O.M. Using a thermal channel (IWIR) to assess crop conditions and predict crop yields. *Electrical engineering and electrical equipment in agriculture*. 2020. Vol. 67. N3(40). 87-94 (In Russian). DOI: 10.22314/2658-4859-2020-67-3-87-94.
 32. Leliuhin D., Tutygin V. System for diagnosing diseases of plant leaves from photographic images obtained using UAVs. *Proceedings of Tula State University*. 2018. N2. 129-137 (In Russian). EDN: RAQZLK.
 33. Pan Q., Gao M., Wu P. et al. A deep-learning-based approach for wheat yellow rust disease recognition from unmanned aerial vehicle images. *Sensors*. 2021. 6540-6553 (In English). DOI: 10.3390/s21196540.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Заявленный вклад соавторов:

Мударисов С.Г. – научное руководство, концептуализация, формирование общих выводов;
Мифтахов И.Р. – поиск и анализ литературы, методология, обсуждение и анализ полученных результатов, подготовка текста статьи.

Авторы прочитали и одобрили окончательный вариант рукописи.

Статья поступила в редакцию

Статья принята к публикации

The paper was submitted to the Editorial Office on

The paper was accepted for publication on

02.07.2024

21.08.2024

Conflict of interest

The authors declare no conflict of interest.

Coauthors' contribution:

Mударисов S.G. – scientific supervision, conceptualization, formulation of general conclusions;
Miftakhov I.R. – literature review, methodology, discussion and analysis of the results obtained, preparation of the manuscript.

The authors read and approved the final manuscript.