

Рациональный метод оценки биотических стрессов растений с использованием машинного обучения

(✉)Алейников А.Ф.^{1,2}, Фуст А.А.²

¹Сибирский федеральный научный центр агробиотехнологий Российской академии наук
Новосибирская область, р.п. Краснообск, Россия

²Новосибирский государственный технический университет
Новосибирск, Россия

(✉)e-mail: fti2009@yandex.ru

Одним из способов восполнения в организме антиоксидантов является добавление в рацион питания человека доли ягодных культур, богатых антиокислительными соединениями. Земляника садовая – самая выращиваемая и потребляемая ягодная культура в мире. Сдерживающие факторы увеличения ее производства – существенное поражение возделываемых сортов широким спектром болезней, основными возбудителями которых являются грибы. Доступных для производителей этой ягодной культуры технических средств диагностики болезней в Российской Федерации не производят. Цель данного исследования – разработать для широкого круга аграриев рациональный метод оценки нескольких биотических стрессов земляники садовой. Среди современных наземных методов диагностики предпочтение отдано методу компьютерного зрения, способному обнаруживать наличие у растения трех грибов – возбудителей белой пятнистости (*Ramularia Tulasnei* Sacc.), бурой пятнистости (*Marssonina potentillae* Desm.) и угловатой пятнистости (*Dendrophoma obscurans*). С применением глубокого обучения с помощью сверточных нейронных сетей (CNN) этот метод может быть реализован в виде приложения к смартфону или другим гаджетам, популярных среди большинства населения. Для глубокого обучения выбраны наиболее распространенные модели CNN. Из сети Интернет вещей (IoT) сформирован набор данных из 2671 изображения, которые были разделены на четыре класса: белая пятнистость (544 шт.), бурая пятнистость (1109), угловатая пятнистость (392), непораженные листья (626 шт.). Набор данных разделен на обучающую выборку (70%), валидационную (10%) и тестовую (20%). При проведении глубокого обучения и операций улучшения моделей нейронных сетей модель нейронной сети MobileNetV2 показала лучшие метрики: значения точности (Ассурасу) классификации – 0,99; *F*-меры – от 0,94 до 1,00.

Ключевые слова: земляника садовая, грибные болезни, глубокое обучение, компьютерное зрение, сверточные нейронные сети

A rational method for assessing biotic stresses in plants using machine learning

(✉)Aleinikov A.F.^{1,2}, Fust A.A.²

¹Siberian Federal Scientific Centre of Agro-BioTechnologies of the Russian Academy of Sciences
Krasnoobsk, Novosibirsk region, Russia

²Novosibirsk State Technical University
Novosibirsk, Russia

(✉)e-mail: fti2009@yandex.ru

One of the ways to replenish antioxidants in the body is to add a share of berry crops rich in antioxidant compounds to the human diet. Garden strawberries are the most grown and consumed berry crop in the world. The restraining factors for increasing the production of garden strawberries are the significant damage of cultivated varieties to a wide range of diseases, the main pathogens of which are fungi. The Russian Federation does not produce technical means for diagnosing diseases available to producers of this berry crop. The purpose of the research is to develop a rational method for assessing several biotic stresses of garden strawberries for a wide range of farmers. Among modern ground-based diagnostic methods, preference is given to the computer vision method, which is capable of detecting the presence of 3 pathogenic fungi: white spot pathogens (*Ramularia Tulasnei* Sacc), brown spot (*Marssonina potentillae* Desm) and angular leaf spot (*Dendrophoma obscurans*).

Using deep learning with convolutional neural networks (CNN), this method can be implemented as an application for a smartphone or other gadgets popular among the majority of the population. The most common CNN models were selected for deep learning. A dataset of 2,671 images was generated from the Internet of Things (IoT) network and divided into 4 classes: white spot (544 pcs.); brown spot (1,109 pcs.); angular spot (392 pcs.); unaffected leaves (626 pcs.). The dataset was divided into a training set of 70%, a validation set of 10%, and a test set of 20%. When conducting deep learning and neural network model improvement operations, the MobileNetV2 neural network model showed the best metrics: classification accuracy – 0.99; *F*-measures from 0.94 to 1.00.

Keywords: garden strawberry, fungal diseases, deep learning, computer vision, convolutional neural networks

Для цитирования: Алейников А.Ф., Фуст А.А. Рациональный метод оценки биотических стрессов растений с использованием машинного обучения // Сибирский вестник сельскохозяйственной науки. 2025. Т. 55. № 4. С. 83–95. <https://doi.org/10.26898/0370-8799-2025-4-9>

For citation: Aleinikov A.F., Fust A.A. A rational method for assessing biotic stresses in plants using machine learning. *Sibirskii vestnik sel'skhozaystvennoi nauki* = *Siberian Herald of Agricultural Science*, 2025, vol. 55, no. 4, pp. 83–95. <https://doi.org/10.26898/0370-8799-2025-4-9>

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest

The authors declare no conflict of interest.

Благодарность

Работа поддержана бюджетным проектом СФНЦА РАН № 0533-2024-0004.

Acknowledgments

The work was supported by the budget project of the SFSCA RAS No. 0533-2024-0004

ВВЕДЕНИЕ

Общеизвестно, что полноценное питание – основа жизнедеятельности человека и один из важнейших факторов, который способствует снижению риска развития у него патологий. Организм человека не способен синтезировать необходимый для его здоровья комплекс антиоксидантов, поэтому значительная часть его должна поступать с пищей, богатой антиокислительными соединениями [1]. Одним из способов восполнения в организме дефицита данных компонентов является добавление в рацион питания человека доли ягодных культур, богатых антиокислительными соединениями [1]. Ягоды оказывают благотворное влияние на работу желудочно-кишечной, сердечно-сосудистой, эндокринной, иммунной, нервной и других систем организма человека [2].

Земляника садовая – наиболее часто выращиваемая и потребляемая ягодная культура в мире. На ее долю приходится свыше 70% общемирового производства ягод [3]. Это обусловлено ее высокими вкусовыми, диетическими и лечебными качествами, а также способностью

к быстрому вегетативному размножению, высокой рентабельностью и урожайностью [3]. Как и в других ягодах, в ней содержится большое количество незаменимых нутриентов. По сравнению с другими ягодами в землянике высокое содержание полифенолов, особенно антоцианов, пищевых волокон, фолиевой кислоты, витаминов, разнообразных микроэлементов (железа, кальция и др.) [4].

В 2019 г. общее мировое производство земляники составило 8,9 млн т. Крупнейшим производителем ягоды был Китай, на долю которого пришлось 40% от общего объема ее производства [5]. Земляника имеет высокий коммерческий спрос во многих странах, поэтому ожидается, что с учетом роста населения и текущей тенденции здорового питания к 2025 г. рынок ее производства возрастет до 11,5 млн т [5].

Существенное отставание объемов российского производства от показателей крупных стран-производителей обусловлено не только неблагоприятными климатическими условиями для производства ягодных культур. Одним из главных сдерживающих факторов увеличения производства ягод земляники садовой является значительное поражение

возделываемых сортов широким спектром болезней. Например, почки, листья, корни, ягоды земляники повреждают более 20 видов возбудителей болезней и более 10 видов вредителей [3]. Землянику садовую поражают свыше 30 грибных, вирусных и бактериальных болезней. Большинство болезней (около 80%) вызывается грибами. При развитии грибных болезней резко (до 60–70%) снижается урожайность ягод.

К сожалению, доступных для производителей этой ягодной культуры технических средств диагностики нескольких биотических стрессов в Российской Федерации нет. Существующие методы ранней диагностики болезней, такие как метод чистых культур, полимеразой цепной реакции, микроскопический, микологический, иммуноферментный анализ, инвазивны, трудоемки и требуют на-

личия высококвалифицированного персонала [3]. Несмотря на высокую достоверность диагноза болезней растений, эти методы не пригодны для их результативного использования на практике в полевых условиях.

Цель исследования – создание метода для оценки биотических стрессов растения, на основе которого возможно разработать техническое средство, доступное для широкого круга производителей-растениеводов.

МАТЕРИАЛ И МЕТОДЫ

Обоснование рационального метода комплекса болезней земляники садовой осуществлено путем анализа современных разрушающих методов диагностики растений и их тенденций развития (см. табл. 1) [6, 7]. Методы мультиспектральной и гиперспектральной визуализации имеют широкие функциональные возможности. В видимой

Табл. 1. Неинвазивные методы диагностики болезней растений

Table 1. Non-invasive methods for diagnosing plant diseases

Принцип	Спектр, нм	Преимущества	Недостатки
<i>Мультиспектральный метод</i>			
Съемка трех диапазонов обычно видимого света (красный R, зеленый G и синий B) и одного или нескольких инфракрасных каналов (ИК) для создания изображений	1. RGB: 380–700 2. Коротковолновой ИК: 900÷2500 3. Средневолновой ИК: 3000÷5000 4. Длинноволновой ИК: 8000÷4000	Съемка позволяет получать дополнительные спектральные данные, которые не видит человеческий глаз, такие как инфракрасные или тепловые излучения	При наличии нескольких разнесенных каналов появляется эффект дублирования изображения. Излучательная способность объекта влияет на результат
<i>Гиперспектральный метод</i>			
При гиперспектральной визуализации используется непрерывный диапазон длин волн с шагом 5 нм	400÷1700	Создает исключительные условия для контроля широкого диапазона свойств растений	Избыточные объемы получаемой информации и высокая сложность методов ее обработки
<i>Метод компьютерного зрения</i>			
Осуществляется анализом изменений цветовых (RGB) параметров изображений листьев растений	380÷780	Определяет внешние симптомы болезни, не видимые невооруженным глазом исследователя	Информация с ограниченными значениями цвета в тоне серого в широкой полосе спектра
<i>Флуоресцентный метод</i>			
Определение концентрации вещества по интенсивности флуоресценции, при облучении монохроматическим излучением	Максимумы: 1. 680÷690 2. 730÷740	Осуществляет оценку поражения растений болезнями, низкими температурами, высокой засоленностью, высокой солнечной радиацией	Необходимость выдерживания растения в полной темноте, сложность выявления биотических стрессов
<i>Метод тепловой визуализации</i>			
Дискретные наборы данных в цветовой палитре	2500÷10400	Позволяет получать съемки в ночное время и при любой погоде	Значительная размытость контуров изображений

области электромагнитного спектра с помощью рассматриваемых методов можно определять цветовые пигменты листьев растений и судить по ним о содержании хлорофилла, каротиноидов, флавонов, антоцианов в конкретном исследуемом растении, а также выявлять симптомы биотического стресса на ранних стадиях болезни. В ближней ИК-области спектра возможно получить информацию о биохимических веществах (белок, вода, крахмал и др.)¹. Однако технические средства реализации спектральной визуализации сложны, дорогостоящи и малоприспособлены для наземного мониторинга растений.

Фотосинтетический статус растения – важный приоритет для оценки культур, подвергающихся воздействиям окружающей среды. Однако необходимость выдерживания растения в полной темноте при определении этого статуса, нечувствительность параметров к резким изменениям влажности окружающего воздуха, сложность автоматизации процедур одновременного выявления биотических стрессов растения ограничивают применение такого метода при диагностике болезней.

Тепловая визуализация нашла широкое распространение при оценке абиотических водных и температурных стрессов, поскольку при засухе закрываются поры устьиц листа, происходит снижение процесса транспирации и его температура повышается [8]. Диагностика и классификация биотических стрессов в данное время затруднены. Например, гриб-возбудитель *Pseudoperonospora cubensis* ложной мучнистой росы на 4-й день инфицирования снижал температуру полого листьев огурца, но когда симптомы ложной мучнистой росы становились видимыми (7-й день развития инфекции) температура повышалась до максимума, а затем резко снижалась. [9]. Гриб-возбудитель *Fusarium virguliforme*, вызывающий синдром внезап-

ной гибели сои, наоборот, повышал температуру полого на ранней стадии развития болезни [10].

Метод компьютерного (технического) зрения заменил трудоемкий процесс визуального наблюдения с участием человека. Однако данный метод приводил к неоднозначным результатам диагноза болезней из-за наличия не-объективности и предвзятости. Применение сложных алгоритмов глубокого обучения в этом методе позволяет получать объективные, точные и масштабируемые решения для измерения различных характеристик и идентификации растений, анализа дефицита питательных веществ и диагностики болезней [11].

В последнее время благодаря быстрому распространению технологий производства гаджетов во всех странах мира широкое применение получили средства измерения и диагностики, основанные на мобильных телефонах. В частности, смартфоны предлагают новые подходы к выявлению болезней растений благодаря своей вычислительной мощности, наличию дисплеев с высоким разрешением и обширному встроенному набору аксессуаров, таких как высокочувствительные HD-камеры². Сочетание широкого распространения смартфонов и роста компьютерных технологий приводит к тому, что диагностика болезней растений на основе автоматизированного распознавания изображений с помощью гаджетов будет доступна в широких масштабах.

Следует учесть, что машинное обучение может занимать много времени, однако обученные модели в сочетании с методами компьютерного зрения могут быстро и точно классифицировать изображения, что делает их приемлемыми для потребительских приложений на смартфонах.

В исследовании использованы три вида грибных болезней земляники садовой, наиболее распространенных в Российской Федерации: белая, бурая и угловатая пятнистости³:

¹Mishra P., Asaari M.S.M., Herrero-Langreo A., Lohumi S., Diezma B., Scheunders P. Close range hyperspectral imaging of plants: a review // Biosystems Engineering. 2017. Vol. 164. P. 49–67. DOI: 10.1016/j.biosystemseng.2017.09.009.

²Mohanty S. P., Hughes D. P., Salathe M. Using deep learning for image-based plant disease detection // Frontiers in Plant Science. 2016. Vol. 7. P. 1419. DOI: 10.3389/fpls.2016.01419.

³Говорова Г.Ф., Говоров Д.Н. Грибные болезни земляники и клубники: монография. М.: Проспект, 2016. 142 с.

– белая пятнистость, возбудитель *Ramularia tulasnei* Sacc.; болезнь поражает листья, черешки, цветоносы, плодоножки, чашелистики; на листьях появляются очень мелкие пурпуровые или красновато-бурые округлые пятна, которые разрастаются в диаметре от 1 до 8 мм, в центре становятся белыми с темно-бурым или пурпуровым ободком, спустя некоторое время побелевший центр пятна выпадает, что присуще только этой болезни листьев земляники;

– бурая пятнистость земляники (*Marssonina potentillae* Desm.); болезнь поражает листья и их черешки, цветоносы, чашелистики и усы земляники; листья и чашелистики покрываются многочисленными от очень мелких (0,1 мм) до крупных (0,5 см) темно-пурпуровыми пятнами, часто расплывчатыми, иногда сливающимися; с верхней стороны листа появляются многочисленные, различные невооруженным глазом блестящие черные подушечки, в которых находятся споры гриба; как с верхней, так и с нижней стороны листа пятна однородно окрашены, без каймы;

– угловатая пятнистость, возбудитель – *Phomopsis (Dendrophoma) obscurans*; болезнь характеризуется появлением на листьях (чаще старых) округлых или неопределенной формы светло-, темно- или красно-коричневых пятен, часто со светлым центром, форма и окраска пятен зависят от сорта; вокруг пятна обычно темно-коричневая или темно-красная кайма, в начале пятна от 1 до 5 мм в диаметре, но вскоре разрастаются до 10–30 мм, иногда вызывая гибель листьев (обычно пятна расположены по краю листовой пластинки или вдоль средней жилки листа).

Для обучения и тестирования моделей взяты наборы данных, состоящих из изображений здоровых листьев клубники садовой, а также пораженных белой, бурой и коричневой пятнистостями^{4,5}.

На рис. 1 представлено несколько изображений из общего набора данных.




Рис. 1. Распространенные грибные болезни земляники садовой:

a – белая пятнистость; *б* – бурая пятнистость; *в* – угловатая пятнистость; *г* – здоровый лист

Fig. 1. Common fungal diseases of garden strawberries: *a* – white spot; *б* – brown spot; *в* – angular spot; *г* – healthy leaf

В наборе данных представлено 2671 изображение. Данные изображения были разделены на четыре класса: белая пятнистость (544 шт.), бурая пятнистость (1109), угловатая пятнистость (392), непораженные листья (626 шт.).

Набор данных разделен на выборки: обучающую (70%), валидационную (10%) и тестовую (20%) (см. табл. 2).

Табл. 2. Распределение изображений на выборке
Table 2. Distribution of images in the sample

Класс	Обучение	Валидация (проверка)	Тестирование
Белая пятнистость	381	54	109
Бурая пятнистость	776	111	222
Угловатая пятнистость	274	39	79
Здоровые листья	438	63	125

⁴Strawberry Disease Detection Dataset <https://www.kaggle.com/datasets/usmanafzaal/strawberry-disease-detection-dataset> (дата обращения 28.02.2025).

⁵Images of Strawberry Leaves for Tipburn Detection <https://www.kaggle.com/datasets/ercanavsar/images-of-strawberry-leaves-for-tipburn-detection/data> (дата обращения 28.03.2025).

Изображения распределены по папкам: «train» с обучающей выборкой, «test» – с тестовой, «val» – с валидационной.

Выборки изображений в папках организованы в кластеры-папки для облегчения загрузки данных через генераторы Keras. Названия папок служили маркерами для дальнейшей классификации изображений, где *angular_spot* – коричневая пятнистость, *brown_spot* – бурая пятнистость, *healthy_leaves* – непораженные листья, *white_spot* – белая пятнистость.

Основополагающие алгоритмы машинного обучения по выборке изображений растений, пораженных грибными болезнями, включают опорные векторные машины (SVM), деревья решений, случайные леса, сверточные нейронные сети (CNN) и трансферное обучение [12]. В ранее проведенных исследованиях показано, что модели глубокого обучения, основанные на CNN, превосходят традиционные методы в идентификации болезней растений на основе изображений [12, 13].

Для классификации болезней использованы модели эффективных сверточных нейронных сетей VGG-16⁶, ResNet-50⁷ и MobileNetV2⁸.

При оценке эффективности моделей использованы метрики Ассурасу, Precision, Recall и *F1*-мера с составляющими их частями (см. табл. 3) [14]:

- истинно положительные (True Positive, TP) – количество примеров, правильно классифицированных как принадлежащих к положительному классу;
- истинно отрицательные (True Negatives, TN) – количество примеров, правильно классифицированных как принадлежащих к отрицательному классу;
- ложно положительные (False Positive, FP) – количество примеров, неправильно

классифицированных как принадлежащих к положительному классу;

- ложно отрицательные (False Negative, FN) – количество примеров, неправильно классифицированных как принадлежащих к отрицательному классу.

В качестве вычислительного устройства использован компьютер, оснащенный процессором Intel Core i5-12400f с тактовой частотой 2,5 ГГц и ОЗУ DDR4 32 Гб с частотой 3200 МГц.

Для обучения моделей выбран язык программирования Python 3.12.8⁹, так как данный язык предлагает множество библиотек и фреймворков для машинного обучения, таких как TensorFlow, Keras, PyTorch, Scikit-Learn и др. Эти библиотеки значительно упрощают процесс разработки и тренировки моделей. Также Python имеет простой и понятный синтаксис. Кроме того, Python легко интегрируется с другими языками и инструментами, что позволяет использовать его в более сложных системах и приложениях.

Для работы с Python используется интегрированная среда разработки PyCharm Community Edition 2024.1.2, разработанная компанией JetBrains. Среда поддерживает множество библиотек и фреймворков для машинного обучения и позволяет легко обучать модели без сложной настройки. Кроме того, важным преимуществом PyCharm является возможность использования настроенного интерпретатора в различных проектах¹⁰.

Основные библиотеки, используемые в проекте, следующие^{11, 12}:

- TensorFlow 2.18.0 (набор инструментов и фреймворков для создания и обучения моделей машинного обучения, работающих на различных платформах, включая мобильные устройства, серверы и облако);

- Keras 3.7.0 (высокоуровневый набор API для машинного обучения, PyCharm дает воз-

⁶VGG16 and VGG19 <https://keras.io/api/applications/vgg/> (дата обращения 28.02.2025).

⁷ResNet and ResNetV2 <https://keras.io/api/applications/resnet/> (дата обращения 28.02.2025).

⁸MobileNet, MobileNetV2, and MobileNetV3 <https://keras.io/api/applications/mobilenet/> (дата обращения 28.02.2025).

⁹Python <https://www.python.org/> (дата обращения 06.03.2025).

¹⁰PyCharm <https://www.jetbrains.com/pycharm/> (дата обращения 06.03.2025).

¹¹TensorFlow <https://www.tensorflow.org/> (дата обращения 06.03.2025).

¹²Keras <https://keras.io/> (дата обращения 06.03.2025).

Табл. 3. Метрики оценки эффективности моделей нейронных сетей
Table 3. Metrics for evaluating the effectiveness of neural network models

Наименование	Формулировка	Суть метрики
Точность	$\text{Precision} = \frac{TP}{TP + FP}$	Доля правильно классифицированных положительных примеров среди всех положительных примеров
Точность (достоверность)	$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$	Доля правильно классифицированных примеров среди всех примеров
Полнота	$\text{Recall} = \frac{TP}{TP + FN}$	Доля правильно классифицированных положительных примеров
F1-мера	$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$	Является гармоническим средним между точностью и полнотой, что позволяет учитывать обе метрики

возможность использования настроенного интерпретатора в проектах. Он является частью TensorFlow и упрощает создание и обучение моделей машинного обучения).

При обучении применяли три библиотеки для работы с данными^{13–15}:

- NumPy 2.0.2 (предоставляет поддержку для работы с многомерными массивами и матрицами, а также для выполнения различных математических и статистических операций);
- Matplotlib 3.10.0 (позволяет визуализировать результаты обучения моделей в виде графиков);
- Scikit-Learn 1.6.0. (инструмент для анализа данных моделей, включающие функции для оценки производительности моделей).

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Для обучения моделей было выбрано 10 эпох. Эпоха – это гиперпараметр, который определяет, сколько раз модель совершит проход по всему тренировочному набору данных¹⁶. В конце каждой эпохи модель проводит тестирование на валидационном наборе

данных, чтобы в ходе обучения отслеживать такие параметры алгоритма, как обучающие, валидационные точности и потери. Затем модель обновляет свои параметры и переходит к следующей эпохе.

Из данных обучения моделей видно, что модель нейронной сети VGG-16 показала достаточно высокие значения метрик; точность модели (Accuracy) составила 0,96; точность (Precision) – 0,87÷1,00; полнота (Recall) – 0,84÷1,00; F1-мера – 0,91÷1,00 (см. табл. 3).

Модель нейронной сети ResNet-50 показала низкие значения метрик. Например, ее точность (Accuracy) составила лишь 0,58. Метрики всех классов показали неудовлетворительные результаты. В данном случае большая разница между метриками Recall (0,74) и Precision (0,42) у класса «Непораженный лист». Это означает, что из 100 изображений всех классов модель причислила к классу «Непораженный лист» 74 изображения, однако только 42 изображения действительно относятся к данному классу. Такая модель хорошо распознает признаки, присущие

¹³NumPy <https://numpy.org/> (дата обращения 06.03.2025).

¹⁴Matplotlib <https://matplotlib.org/> (дата обращения 06.03.2025).

¹⁵Scikit-Learn <https://scikit-learn.org/stable/> (дата обращения: 06.03.2025).

¹⁶What is Epoch in Machine Learning? <https://www.simplilearn.com/tutorials/machine-learning-tutorial/what-is-epoch-in-machine-learning> (дата обращения 06.03.2025).

Табл. 3. Результаты обучения моделей нейронных сетей

Table 3. Results of training neural network models

Класс	Accuracy	Precision	Recall	F1-мера
<i>VGG-16</i>				
Угловатая пятнистость	0,96	0,96	0,96	0,96
Бурая пятнистость		1,00	1,00	1,00
Непораженный лист		0,87	0,99	0,93
Белая пятнистость		0,99	0,84	0,91
<i>ResNet-50</i>				
Угловатая пятнистость	0,58	0,00	0,00	0,00
Бурая пятнистость		0,73	0,96	0,83
Непораженный лист		0,42	0,74	0,54
Белая пятнистость		0,28	0,06	0,10
<i>MobileNetV2</i>				
Угловатая пятнистость	0,99	1,00	0,94	0,97
Бурая пятнистость		1,00	1,00	1,00
Непораженный лист		0,98	0,98	0,98
Белая пятнистость		0,95	1,00	0,97

этому классу, но совершает много ошибок в классификации истинно положительных изображений. Кроме того, модель нейронной сети ResNet-50 совершенно не распознала класс «Угловатая пятнистость».

Модель нейронной сети MobileNetV2 среди рассматриваемых моделей показала наилучшие результаты по нахождению признаков каждого класса: точность (Accuracy) составила 0,99; полнота (Recall) – в интервале 0,94÷1,00 и точность (Precision) в интервале 0,95÷1,00.

На рис. 2 представлены графические интерпретации тренда точности и потерь обучения и валидации по эпохам трех моделей нейронной сети.

Для модели нейронной сети VGG-16 потери обучения уменьшаются, а точность увеличивается, что свидетельствует о правильном поведении модели в процессе обучения. Однако потери и точность валидации сильно колеблются, при этом точность валидации не располагается на уровне точности обучения.

Модель нейронной сети ResNet-50 по трендам показывает наилучшую тенденцию, так как потери валидации уменьшаются, а точность увеличивается. Причинами низких значений метрик при правильном поведении модели в процессе обучения могут быть небольшое количество изображений в наборе; недостаточно наглядные изображения (модель не может обобщить признаки на изображениях); сложность модели или недостаточное количество эпох (модель не успевает обучиться).

Модель нейронной сети MobileNetV2 имеет хорошие метрики и тенденцию работы, но значения точности и потерь валидации некорректны. Эффективность модели зависит не только от результатов обучения, но и от правильного поведения модели в процессе обучения. Данную модель необходимо настроить и заново обучить, что может привести к корректному тренду точности и потерь валидации. В связи с этим были применены методы регуляризации и изменения гиперпараметров¹⁷.

В табл. 4 представлены результаты обучения улучшенных моделей нейронных сетей VGG-16, ResNet-50 и MobileNetV2. Модель VGG-16 показала высокие значения метрик, достоверность ее составила 0,96. У модели ResNet-50 более низкие значения метрик, ее точность (Accuracy) имеет значение 0,52.

На рис. 3. представлена графическая интерпретация тренда точности и потерь обучения и валидации по эпохам трех улучшенных моделей. Улучшенная модель VGG-16 в целом имеет правильное поведение в процессе обучения. У модели ResNet-50 потери обучения уменьшаются, а точность увеличивается, что свидетельствует о правильном поведении модели в процессе обучения. Однако потери валидации колеблются, не отмечено снижения потерь, точность валидации в целом увеличивается, но она обладает временной нестабильностью.

¹⁷Gobov D., Solovei O. Approaches to Improving the Accuracy of Machine Learning Models in Requirements Elicitation Techniques Selection // ResearchGate. 2023. P. 11. DOI: 10.48550/arXiv.2303.14762.




Рис. 2. Результаты обучения моделей: — обучающие; --- валидационные
Fig. 2. Results of model training: — training; --- validation

Табл. 4. Результаты обучения улучшенных моделей нейронных сетей
Table 4. Results of training improved neural network models

Класс	Accu- racy	Preci- sion	Recall	F1-мера
<i>VGG-16</i>				
Угловатая пятнистость	0,96	0,97	0,90	0,93
Бурая пятнистость		0,99	1,00	1,00
Непораженный лист		0,88	0,99	0,93
Белая пятнистость		0,97	0,86	0,91
<i>ResNet-50</i>				
Угловатая пятнистость	0,52	0,14	0,01	0,02
Бурая пятнистость		0,74	0,95	0,83
Непораженный лист		0,30	0,34	0,32
Белая пятнистость		0,21	0,21	0,21
<i>MobileNetV2</i>				
Угловатая пятнистость	0,97	0,96	0,95	0,96
Бурая пятнистость		1,00	1,00	1,00
Непораженный лист		0,94	1,00	0,97
Белая пятнистость		0,98	0,91	0,94

Из всех ранее обученных моделей MobileNetV2 показала наилучшие результаты точности и потерь обучения и валидации. Можно увидеть, что потери снижаются монотонно, а точность валидации имеет небольшие колебания на уровне точности обучения. К 10-й эпохе эти потери стабилизируются и соответствуют уровню точности обучения.

Все результаты проведенных исследований моделей сведены в табл. 5, 6.

Таким образом, при глубоком обучении трех моделей нейронных сетей модель сети MobileNetV2 показала лучшие результаты по метрикам и параметрам: значение точности (Accuracy) составило 0,99; F1-меры – от 0,94 до 1,00 ед.




Рис. 3. Результаты обучения улучшенных моделей: — обучающие; --- валидационные

Fig. 3. Results of training improved models: — training; --- validation

Табл. 5. Метрики моделей нейронных сетей до и после обучения

Table 5. Metrics of neural network models before and after training

Класс	Ассурасу (до улучшения)	F1-мера (до улучшения)	Ассурасу (после улучшения)	F1-мера (после улучшения)
VGG-16				
Коричневая пятнистость	0,96	0,96	0,96	0,93
Бурая пятнистость		1,00		1,00
Непораженный лист		0,93		0,93
Белая пятнистость		0,91		0,91
ResNet-50				
Коричневая пятнистость	0,58	0,00	0,52	0,02
Бурая пятнистость		0,83		0,83
Непораженный лист		0,54		0,32
Белая пятнистость		0,10		0,21
MobileNetV2				
Коричневая пятнистость	0,99	0,97	0,97	0,96
Бурая пятнистость		1,00		1,00
Непораженный лист		0,98		0,97
Белая пятнистость		0,97		0,94

Табл. 6. Параметры обучения моделей нейронных сетей

Table 6. Training parameters of neural network models

Модель	Время обучения, мин	Вес, Мб
VGG-16	19,5	129
ResNet-50	14,1	96,3
MobileNetV2	10,9	13

ВЫВОДЫ

1. Анализ современных методов оценки болезней растений показал, что метод компьютерного (технического) зрения более рационален для наземной диагностики. При применении алгоритмов глубокого обучения этот метод позволяет получать объективные и точные решения при обнаружении и классификации биотических стрессов у культурных растений. На основе метода компьютерного зрения может быть разработан прибор в виде программного приложения к гаджетам, популярным среди большинства населения.

2. Предметом для исследований служили листья растений земляники садовой неизвестных сортов, пораженных наиболее распространенными грибными болезнями: белой, бурой и угловатой пятнистостями. Из сети Интернет вещей сформирован набор данных из 2671 изображения, которые были разделены на четыре класса: белая пятнистость (544 шт.), бурая пятнистость (1109), угловатая пятнистость (392), непораженные листья (626 шт.). Набор данных был разделен на обучающую выборку (70%), валидационную (10%) и тестовую (20%).

3. Для глубокого обучения были выбраны наиболее широко распространенные на практике модели сверточных нейронных сетей VGG-16, ResNet-50 и MobileNetV2.

4. При проведении глубокого обучения и операций улучшения моделей нейронных сетей модель нейронной сети MobileNetV2 показала лучшие результаты метрик: значение точности – 0,99 и F1-меры – от 0,94 до 1,00 ед.

СПИСОК ЛИТЕРАТУРЫ

1. Mukherjee E., Gantait S. Strawberry biotechnology: A review on progress over past 10 years // *Scientia Horticulturae*. 2024. Vol. 338. P. 113618. DOI: 10.1016/j.scienta.2024.113618.

2. Sahapoglu B., Erskine E., Subasi B.G., Capanoglu E. Recent studies on berry bioactives and their health-promoting roles // *Molecules*. 2022. Vol. 27. N 108. P. 2–24. DOI: 10.3390/molecules27010108.

3. Алейников А.Ф. Метод неинвазивного определения грибных болезней земляники садовой // *Сибирский вестник сельскохозяйственной науки*. 2018. Т. 48. № 3. С. 71–83 DOI: 10.26898/0370-8799-2018-3-10.

4. Fu H., Wang L., Gu J., Peng X., Zhao J. Effects of Litsea cubeba essential oil–chitosan/corn starch composite films on the quality and shelf-life of strawberry (*Fragaria × ananassa*) // *Foods*. 2024. Vol. 13. N 4. P. 599. DOI: 10.3390/foods13040599.

5. Hernández-Martínez N.R., Blanchard C., Wells D.M. Salazar-Gutiérrez M. Current state and future perspectives of commercial strawberry production: A review // *Scientia Horticulturae*. 2023. Vol. 312 (10). P. 111893. DOI: 10.1016/j.scienta.2023.111893.

6. Wen T., Li J.H., Wang Q., Gao Y.Y., Hao G.F., Song B.A. Thermal imaging: The digital eye facilitates high-throughput phenotyping traits of plant growth and stress responses // *Science of The Total Environment*. 2023. Vol. 899. P. 165626. DOI: 10.1016/j.scitotenv.2023.165626.

7. Алейников А.Ф. Перспективный метод диагностики болезни растений и определения их фенотипа // *Сибирский вестник сельскохозяйственной науки*. 2025. Т. 55. № 1 (314). С. 90–106. DOI: 10.26898/0370-8799-2025-1-11.

8. Chandel N.S., Rajwade Y.A., Dubey K., Chandel A.K., Subeesh A., Tiwari M.K. Water stress identification of winter wheat crop with state-of-the-art al techniques and high-resolution thermal-RGB imagery // *Plants-Basel*. 2022. Vol. 11 (2). P. 3344. DOI: 10.3390/plants11233344.

9. Wen D.M., Chen M.X., Zhao L., Ji T., Li M., Yang X.T. Use of thermal imaging and Fourier transform infrared spectroscopy for the pre-symptomatic detection of cucumber downy mildew // *European Journal of Plant Pathology*. 2019. Vol. 155. P. 405–416. DOI: 10.1007/s10658-019-01775-2.

10. Hatton N., Sharda A., Schapaugh W., Van Der Merwe D. Remote thermal infrared imaging for rapid screening of sudden death syndrome in soybean // *Computers and Electronics in Agriculture*. 2020. Vol. 178. P. 105738. DOI: 10.1016/j.compag.2020.105738.
11. Zheng C., Abdulrahman A., Whitaker V. Remote sensing and machine learning in crop phenotyping and management, with an emphasis on applications in strawberry farming // *Remote Sensing*. 2021. Vol. 13 (3). P. 531. DOI: 10.3390/rs1303053.
12. Batham S., Sharma A.K., Rathore A.S. A Research Paper on Crop Disease Detection Using Deep Learning Model // *International Journal for Research in Applied Science and Engineering Technology*. 2023. Vol. 11 (31). P. 399–406. DOI: 10.22214/ijraset.2023.56002.
13. Ezigbo L.I., Chibueze K.I. Optimized Machine Learning System for Identifying Plant Diseases // *International Journal of Latest Technology in Engineering Management & Applied Science*. 2025. Vol. 13 (12). P. 66–74. DOI: 10.51583/IJLTEMAS.2024.131207.
14. Miller C., Portlock T., Nyaga D.M. A review of model evaluation metrics for machine learning in genetics and genomics // *Frontiers*. 2024. Vol. 4. P. 1457619. DOI: 10.3389/fbinf.2024.1457619.
5. Hernández-Martínez N.R., Blanchard C., Wells D.M., Salazar-Gutiérrez M. Current state and future perspectives of commercial strawberry production: A review. *Scientia Horticulturae*, 2023, vol. 312 (10), p. 111893. DOI: 10.1016/j.scienta.2023.111893.
6. Wen T., Li J.H., Wang Q., Gao Y.Y., Hao G.F., Song B.A. Thermal imaging: The digital eye facilitates high-throughput phenotyping traits of plant growth and stress responses. *Science of the Total Environment*, 2023, vol. 899, p. 165626. DOI: 10.1016/j.scitotenv.2023.165626.
7. Aleynikov A.F. A promising method for diagnosing plant diseases and determining their phenotype. *Sibirskii vestnik sel'skokhozyaistvennoi nauki = Siberian Herald of Agricultural Science*, 2025, vol. 55, no. 1 (314), pp. 90–106. (In Russian). DOI: 10.26898/0370-8799-2025-1-11.
8. Chandel N.S., Rajwade Y.A., Dubey K., Chandel A.K., Subeesh A., Tiwari M.K. Water stress identification of winter wheat crop with state-of-the-art al techniques and high-resolution thermal-RGB imagery. *Plants-Basel*, 2022, vol. 11 (2), p. 3344. DOI: 10.3390/plants11233344.
9. Wen D.M., Chen M.X., Zhao L., Ji T., Li M., Yang X.T Use of thermal imaging and Fourier transform infrared spectroscopy for the pre-symptomatic detection of cucumber downy mildew. *European Journal of Plant Pathology*, 2019, vol. 155, pp. 405–416. DOI: 10.1007/s10658-019-01775-2.
10. Hatton N., Sharda A., Schapaugh W., Van Der Merwe D. Remote thermal infrared imaging for rapid screening of sudden death syndrome in soybean. *Computers and Electronics in Agriculture*, 2020, vol. 178, p. 105738. DOI: 10.1016/j.compag.2020.105738.
11. Zheng C., Abdulrahman A., Whitaker V. Remote sensing and machine learning in crop phenotyping and management, with an emphasis on applications in strawberry farming. *Remote Sensing*, 2021, vol. 13 (3), p. 531. DOI: 10.3390/rs1303053.
12. Batham S., Sharma A.K., Rathore A.S. A Research Paper on Crop Disease Detection Using Deep Learning Model. *International Journal for Research in Applied Science and Engineering Technology*, 2023, vol. 11 (31), pp. 399–406. DOI: 10.22214/ijraset.2023.56002.
13. Ezigbo L.I., Chibueze K.I. Optimized Machine Learning System for Identifying Plant Diseases.

REFERENCES

1. Mukherjee E., Gantait S. Strawberry biotechnology: A review on progress over past 10 years. *Scientia Horticulturae*, 2024, vol. 338, p. 113618. DOI: 10.1016/j.scienta.2024.113618.
2. Sahapoglu B., Erskine E., Subasi B.G., Capanoglu E. Recent studies on berry bioactives and their health-promoting roles. *Molecules*, 2022, vol. 27, no. 108, pp. 2–24. DOI: 10.3390/molecules27010108.
3. Aleynikov A.F. Method of non-invasive determination of fungal diseases of common garden strawberry. *Sibirskii vestnik sel'skhozyastvennoi nauki = Siberian Herald of Agricultural Science*, 2018, vol. 48, no. 3, pp. 71–83. (In Russian). DOI: 10.26898/0370-8799-2018-3-10.
4. Fu H., Wang L., Gu J., Peng X., Zhao J. Effects of Litsea cubeba essential oil–chitosan/corn starch composite films on the quality and shelf-life of strawberry (*Fragaria × ananassa*). *Foods*, 2024, vol. 13, no. 4, p. 599. DOI: 10.3390/foods13040599.

International Journal of Latest Technology in Engineering Management & Applied Science, 2025, vol. 13 (12), pp. 66–74. DOI: 10.51583/IJLTEMAS.2024.131207.

14. Miller C., Portlock T., Nyaga D.M. A review of model evaluation metrics for machine learning in genetics and genomics. *Frontiers*, 2024, vol. 4, p. 1457619. DOI: 10.3389/fbinf.2024.1457619.

ИНФОРМАЦИЯ ОБ АВТОРАХ

✉ **Алейников А.Ф.**, ¹главный научный сотрудник, доктор технических наук, профессор; ²профессор кафедры; SPIN-код 6885-7554; **адрес для переписки:** Россия, 630501, Новосибирская область, р.п. Краснообск, а/я 463; e-mail: fti2009@yandex.ru.

Фуст Алина А., магистрант кафедры

AUTHOR INFORMATION

✉ **Alexander F. Aleynikov**, ¹Head Researcher, Doctor of Science in Engineering, Professor; ²Chair Professor; SPIN-code 6885-7554; **address:** PO Box 463, Krasnoobsk, Novosibirsk Region, 630501, Russia; e-mail: fti2009@yandex.ru

Alina A. Fust, Master's Degree Student

Дата поступления статьи / Received by the editors 31.01.2025
Дата принятия к публикации / Accepted for publication 12.03.2025
Дата публикации / Published 15.05.2025