

ПРИМЕНЕНИЕ АРХИТЕКТУР ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ИДЕНТИФИКАЦИИ ЗАБОЛЕВАНИЙ ДЕРЕВЬЕВ ПО ИЗОБРАЖЕНИЯМ

APPLICATION OF DEEP LEARNING ARCHITECTURES TO IDENTIFICATION OF TREE DISEASES FROM IMAGES

**N. Verezubova
N. Yakovleva
A. Chekulaev**

Summary. This paper focuses on automating the diagnosis of woody plant pathologies using deep learning methods. The relevance of the study lies in the need for timely detection of fungal infections to minimize environmental and economic damage. A dataset of leaf images was used, including healthy specimens and those affected by *Uromyces appendiculatus* (rust) and *Mycosphaerella angulata* (angular leaf spot). The methodology is based on a deep neural network with a contrastive learning strategy (SimCLR) and subsequent supervised retraining. The Grad-CAM attention visualization algorithm was used to verify decisions and ensure the interpretability of the model. The results confirm the effectiveness of the proposed approach for accurate disease identification and its applicability to intelligent plant monitoring systems.

Keywords: neural networks, computer vision, plant pathology, contrastive learning.

Вerezubova Наталья Афанасьевна

Кандидат экономических наук, доцент, Московская государственная академия ветеринарной медицины и биотехнологии имени К.И. Скрябина
nverez@mail.ru

Яковлева Ольга Анатольевна

Кандидат сельскохозяйственных наук, доцент, Московская государственная академия ветеринарной медицины и биотехнологии имени К.И. Скрябина
yakovleffo@yandex.ru

Чекулаев Артур Анатольевич

Московская государственная академия ветеринарной медицины и биотехнологии имени К.И. Скрябина

Аннотация. Работа посвящена автоматизации диагностики патологий древесных растений с применением методов глубокого обучения. Актуальность исследования обусловлена необходимостью своевременного выявления грибковых инфекций для минимизации экологического и экономического ущерба. В качестве материала использован набор изображений листьев, включающий здоровые образцы и экземпляры, пораженные *Uromyces appendiculatus* (ржавчина) и *Mycosphaerella angulata* (угловая пятнистость). Методология базируется на использовании глубокой нейронной сети с применением стратегии контрастного предварительного обучения (SimCLR) и последующего контролируемого дообучения. Для верификации принимаемых решений и обеспечения интерпретируемости модели использован алгоритм визуализации внимания Grad-CAM. Результаты подтверждают эффективность предложенного подхода для точной идентификации болезней и его применимость в системах интеллектуального мониторинга насаждений.

Ключевые слова: нейронные сети, компьютерное зрение, фитопатология, контрастное обучение.

Введение

Сохранение здоровья лесных массивов и сельскохозяйственных насаждений является фундаментальным условием обеспечения экологической стабильности и продовольственной безопасности. Деревья, выступая ключевым звеном биосферы, подвержены широкому спектру патологических воздействий. Распространение фитопатогенов — грибковой, бактериальной или вирусной природы — ежегодно приводит к существенным потерям биомассы и наносит значительный экономический ущерб лесопромышленному и аграрному секторам [1].

В условиях меняющегося климата, способствующего миграции вредителей и болезней, задача своевременного выявления патологий становится критически важной.

Традиционные методы мониторинга состояния деревьев преимущественно опираются на визуальный осмотр, проводимый профильными специалистами-фитопатологами [2]. Однако данный подход обладает рядом существенных ограничений: он трудоемок, требует высокой квалификации персонала и плохо поддается масштабированию на большие территории. Кроме того, человеческий фактор неизбежно вносит элемент субъективности в диагностику, что может приводить

к ошибкам на ранних стадиях развития заболевания, когда визуальные симптомы еще слабо выражены. Лабораторные же методы, хоть и точны, требуют значительных временных затрат, что часто не позволяет принять оперативные меры по локализации очага заражения.

В последние годы развитие методов искусственного интеллекта, и, в частности, технологий глубокого обучения (Deep Learning), открыло новые перспективы в области автоматизированной диагностики. Сверточные нейронные сети продемонстрировали исключительную эффективность в задачах компьютерного зрения, позволяя выявлять сложные закономерности на цифровых изображениях, недоступные человеческому глазу. Применение подобных алгоритмов для анализа изображений листьев, коры или стволов деревьев позволяет создать системы неинвазивного, быстрого и точного мониторинга [3, 4].

Целью данной работы является разработка и исследование эффективности метода классификации болезней деревьев на основе глубоких нейронных сетей. В рамках исследования решается задача подбора алгоритмической модели, способной с высокой точностью идентифицировать тип патологии по визуальным признакам, минимизируя при этом вероятность ложноположительных и ложноотрицательных результатов.

Актуальность данного подхода обусловлена необходимостью перехода к точному земледелию и лесоводству, где автоматизация процессов диагностики служит основой для принятия своевременных и обоснованных решений по защите растений.

Материалы и методы

Эмпирическую базу для проведения вычислительных экспериментов составил аннотированный набор цифровых изображений, фиксирующих состояние листового аппарата растений. Для решения задачи классификации сформированный массив данных был структурирован и разделен на три диагностические категории, что позволяет обучить модель дифференцировать здоровые и патологически измененные образцы.

Первая группа изображений представляет собой выборку, характеризующуюся наличием признаков поражения ржавчиной. Этиология данного инфекционного процесса связана с воздействием патогенного гриба *Uromyces appendiculatus* (bean_rust).

На снимках, отнесенных к данному классу, отчетливо прослеживаются специфические визуальные маркеры микоза: характерные пустулы и изменения пигментации ткани листа. Использование таких данных необходимо для настройки чувствительности нейросети к текстур-

ным и цветовым аномалиям, свойственным грибковым инфекциям.

Вторая группа сформирована из изображений листьев винограда с симптоматикой угловой пятнистости. Возбудителем данной патологии выступает гриб *Mycosphaerella angulata* (angular_leaf_spot).

Включение этого класса в обучающую выборку позволяет модели научиться идентифицировать специфические некротические паттерны, отличающиеся по своей геометрии и локализации от проявлений ржавчины, что повышает обобщающую способность алгоритма при работе с различными типами фитопатогенов.

Третья группа является контрольной и содержит снимки листьев, не имеющих внешних проявлений инфекционных или грибковых заболеваний (healthy).

Наличие «здорового» класса критически важно для верификации работы модели: это позволяет минимизировать уровень ложноположительных срабатываний и научить нейронную сеть корректно классифицировать норму, отличая ее от патологических состояний.

Методологическая стратегия работы базируется на применении архитектуры глубоких нейронных сетей с использованием двухступенчатого протокола обучения. В качестве подхода для формирования признаков пространства выбран метод SimCLR (Simple Framework for Contrastive Learning of Visual Representations), реализующий парадигму контрастивного обучения [5, 6, 7].

Процесс построения классификатора разделен на два последовательных этапа: на данном этапе модель обучается в режиме самообучения (self-supervised learning), не используя информацию о метках классов. Алгоритм SimCLR оптимизирует параметры сети, минимизируя расстояние в векторном пространстве между различными аугментированными версиями одного и того же изображения и максимизируя его для отличающихся объектов. Это позволяет модели сформировать устойчивые и информативные визуальные представления (эмбеддинги), выделяя ключевые структурные особенности листьев независимо от их патологического статуса.

На втором этапе производится точная настройка весов предварительно обученной сети с использованием целевого аннотированного набора данных (обучение с учителем). На этой стадии к модели добавляется классификационный слой, и происходит адаптация сформированных признаков для решения конкретной задачи дифференциации трех описанных групп: здоровых растений и образцов, пораженных специфическими патогенами [8].




Рис. 1. Аугментированные изображения, используемые контрастным алгоритмом




Рис. 2. Кривая обучения по батчам

С целью валидации системы был применён ряд методов. В качестве базового метода контроля модели, как во время стадии тренировки, в том числе и в течение периода предтренировки, так и во время проверки системы, с нейронной сети были сняты метрики качества её работы.

Такие метрики как F-1, Accuracy, Loss были применены в данном моделировании. Перечисленные показатели качества влияли не только на оценку контролируемого обучения постфактум, но и непосредственно на его ход, контролируя его течения при помощи оптимизации модели вида Grid Search.

Контролируемая модель обучалась до достижения максимальной сходимости, в то время как на SSL этапе система должна была достигнуть максимальной косинусной схожести аугментаций одного и того же образца.

Для всесторонней верификации работы алгоритма, помимо стандартных количественных метрик оценки производительности (точность, полнота, F-мера), был применен метод визуальной интерпретации решений сверточных нейронных сетей — Grad-CAM (Gradient-weighted Class Activation Mapping) [9, 10, 11].

Интеграция данного инструмента позволяет решить проблему «черного ящика», свойственную методам глубокого обучения. Технология Grad-CAM генерирует тепловые карты активации, накладываемые на исходное изображение. Эти карты визуализируют распределение «внимания» модели, выделяя конкретные области листа, которые внесли решающий вклад в присвоение того или иного класса. Такой подход дает возможность качественно оценить адекватность обучения: он подтверждает, что искусственная нейронная сеть идентифицирует заболевание, опираясь именно на специфические признаки патологии (очаги некроза, грибковые образования), а не на посторонние шумы или артефакты фона.

Результаты и обсуждение

В начале обучения описанной ранее системы были выведены как сами анализируемые алгоритмом образцы, так и их аугментации, непосредственно используемые для обучения модели. Данная визуализация продемонстрирована на рисунке 1.

Оценив визуально данное изображение, можно сделать вывод о высоком разнообразии данных, подающихся на вход модели. Данный фактор критически необходим для качественного обучения контрастивной модели.

После завершения первого этапа обучения была выведена кривая обучения по батчам. Рисунок 2 демонстрирует описанную кривую.

Данный график описывает эффект аппроксиматического уменьшения потери и как следствие качественного обучения системы. Стоит отметить относительно небольшую разницу между начальным лоссом и конечным, что может означать применение небольшого количества эпох при обучении системы.

Важным показателем, дополняющим показания кривой, является матрица сходства, представленная на рисунке 3.

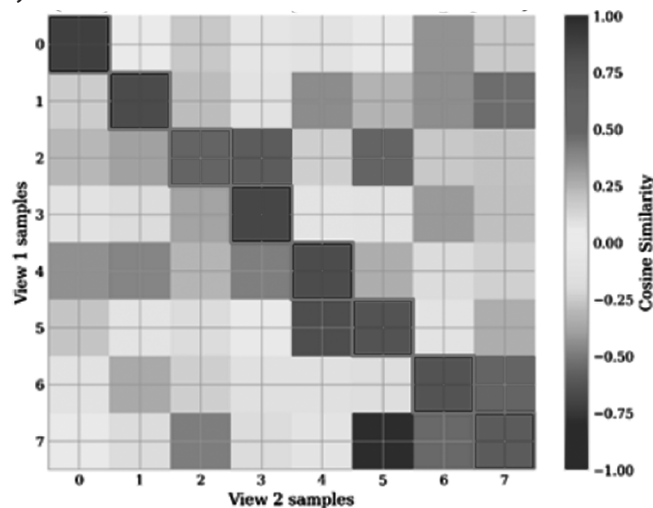


Рис. 3. Косинусное сходство образцов на заключительной эпохе

Данная матрица демонстрирует максимальное сходство между разными версиями одного и того же изображения и максимальную разницу между различными между собой экземплярами.

Итоговый вид данной визуализации свидетельствует о качественном обучении самоконтролируемого этапа обучения.

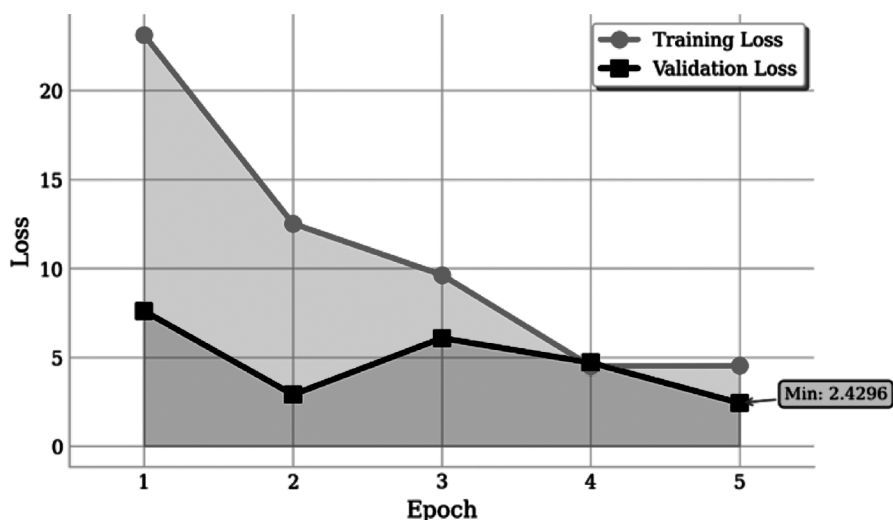


Рис. 4. Кривые обучения контролируемого этапа обучения

После получения контрастного энкодера модель была обучена контролируемо. На этом этапе были получены метрики качества и кривые обучения.

На рисунке 4 показаны кривые потерь валидации и тренировки.

Из данного рисунка следует что модель обучалась вполне стабильно, однако высокая потеря может свидетельствовать в том числе о малом количестве данных, поданных на вход модели. Однако несмотря на повышенный loss, система показала адекватное соотношения правильно и неправильно предсказанных классов, что продемонстрировано на рисунке 5, представляющий собой матрицу ошибок.




Рис. 5. Матрица путаницы (ошибок) полученная на контролируемом этапе обучения

Исходя из данной матрицы можно сделать вывод о небольшом количестве неправильно предсказанных

моделью результатов, это может свидетельствовать о высоком качестве обучения сети.

Метрики, полученные в данном эксперименте, подтверждают работоспособность метода глубокого обучения. Их показатели представлены в таблице 1.

Таблица 1.

Метрики системы

Metric	Value
Val Accuracy	0.9630
Val F-1 score	0.9610
Min Val Loss	2.4296

Опираясь на данные таблицы, можно прийти к выводу, что система достигла баланса в соотношении правильных и неправильных предсказаний, имея высокую долю верно положительных результатов.

Для подтверждения высокого качества обучения были выведены Grad-CAM визуализации, представленные на рисунке 6.

Из приведённого изображения можно сделать вывод, что модель «концентрирует внимание» на признаконесущих фрагментах, данных на вход.

На основании проведённого исследования можно сделать вывод, что модель контрастного обучения справилась с задачей не только определения наличия поражённости исследуемых листьев патогеном, но и классификации самих патологических состояний.

Выводы

Проведенное исследование подтвердило высокую эффективность применения методов глубокого




Рис. 6. Grad-CAM итоговой модели

обучения для решения задач автоматизированной диагностики фитопатологий. Предложенная архитектура нейронной сети, использующая стратегию двухэтапного обучения — предварительную подготовку методом SimCLR с последующим контролируемым дообучением, — продемонстрировала устойчивую способность к дифференциации здоровых тканей и образцов, пораженных грибковыми инфекциями (*Uromyces appendiculatus* и *Mycosphaerella angulata*).

Использование контрастивного обучения позволило модели сформировать качественные признаковые представления даже в условиях ограниченного объема размеченных данных, что особенно актуально для специфических задач лесопатологии. Важным результатом работы стало подтверждение адекватности принимаемых нейросетью решений: применение алгоритма Grad-CAM показало, что фокус внимания модели при

классификации совпадает с реальной локализацией клинических симптомов заболеваний (пустул и некротических пятен), исключая вероятность ложного срабатывания на фоновые объекты.

Полученные результаты свидетельствуют о перспективности внедрения разработанного подхода в практические системы мониторинга. Интеграция подобных алгоритмов в комплексы точного земледелия и лесохозяйства позволит существенно повысить оперативность выявления биологических угроз, минимизировать человеческий фактор при осмотре насаждений и, как следствие, снизить экономические и экологические риски. Дальнейшее развитие работы видится в расширении спектра диагностируемых патологий и адаптации модели для работы в условиях реального времени на мобильных платформах.

ЛИТЕРАТУРА

1. Проблемы и мониторинг природных экосистем: сборник статей V Всероссийской научно-практической конференции, Пенза, 29 октября 2018 года / Пензенский государственный аграрный университет, Межотраслевой научно-информационный центр; Саратовский национальный исследовательский государственный университет имени Н.Г. Чернышевского. — Пенза: Пензенский государственный аграрный университет, 2018. — 178 с. — ISBN 978-5-94338-934-4.
2. Ступина А.В. Фитопатологический мониторинг лесных экосистем / А.В. Ступина // Молодая мысль: наука, технологии, инновации: материалы VII (XIII) Всероссийской научно-технической конференции студентов, магистрантов, аспирантов и молодых ученых, Братск, 16–20 марта 2015 года. — Братск: Братский государственный университет, 2015. — С. 88–90.
3. Ступичев А.К. Распознавание образов и обучение нейронных сетей / А.К. Ступичев, И.П. Парфенов // Фундаментальные и прикладные исследования молодых учёных: сборник материалов VII Международной научно-практической конференции студентов, аспирантов и молодых учёных, приуроченной к 110-летию со дня рождения Т.В. Алексеевой, Омск, 20–21 апреля 2023 года. — Омск: Сибирский государственный автомобильно-дорожный университет (СибАДИ), 2023. — С. 533–537.
4. Kuznetsov A. Digital image forgery detection using deep learning approach / A. Kuznetsov // Сборник трудов ИТНТ-2019, Самара, 21–24 мая 2019 года. Vol. 2. — Самара: Новая техника, 2019. — P. 373–376. — DOI 10.1088/1742–6596/1368/3/032028.
5. Еленников Г.М. Машинное обучение нейронных сетей «без учителя» / Г.М. Еленников, Л.Д. Гусева, Е.В. Ершов // Современные информационные технологии. Теория и практика: Материалы VI Всероссийской научно-практической конференции: В 2-х частях, Череповец, 29 ноября 2023 года. — Череповец: Череповецкий государственный университет, 2024. — С. 211–216.
6. Chen T., Kornblith S., Norouzi M., Hinton G. A Simple Framework for Contrastive Learning of Visual Representations // Proceedings of the 37th International Conference on Machine Learning. — Vienna, Austria: PMLR, 2020. — Vol. 119. — arXiv:2002.05709v3 [cs.LG].
7. Jiang D. Speech SimCLR: Combining Contrastive and Reconstruction Objective for Self-supervised Speech Representation Learning / D. Jiang, W. Li, M. Cao, W. Zou, X. Li // arXiv preprint arXiv:2010.13991. — 2021. — 5 July.
8. Rodchenko V.G. Supervised Learning: from the allocation algorithm to the identification of hidden interpretable patterns / V.G. Rodchenko // Открытые семантические технологии проектирования интеллектуальных систем. — 2020. — No. 4. — P. 253–256.
9. Чайка К.В. Оценивание качества обучения нейросетевых алгоритмов обработки информации / К.В. Чайка, Р.П. Шестопалов // Информационно-экономические аспекты стандартизации и технического регулирования. — 2021. — № 2(60). — С. 17–26.
10. Реусова Т.В. Оценка качества шкурки пушных зверей с помощью компьютерного зрения: ключевые параметры / Т.В. Реусова, Н.А. Везубова, М.В. Новиков // Трансформации современного общества: теоретические и практические аспекты: Материалы VII Международной научно-практической конференции, Москва, 24–25 апреля 2025 года. — Москва: Московский институт экономики, политики и права, 2025. — С. 157–161.
11. Neural Network Analysis of Meat Quality: A Comparative Study of Forward-Forward and Backpropagation Learning Methods / N.A. Verezubova, A. Chekulaev, O. Yakovleva [et al.] // Smart Cities and Sustainable Regional Development (SMARTGREENS 2025), Екатеринбург, 25 сентября 2025 года. — Екатеринбург: Institute of Digital Economics and Law, 2025. — P. 190–196. — DOI 10.63550/ICEIP.2025.99.27.026.

© Везубова Наталья Афанасьевна (nverez@mail.ru); Яковлева Ольга Анатольевна (yakovleffo@yandex.ru);
Чекулаев Артур Анатольевич

Журнал «Современная наука: актуальные проблемы теории и практики»