

УДК 004.81

Распознавание болезней листьев с помощью методов глубокого обучения

Мутхана Али Салем Али¹

m2112648@edu.misis.ru

Ляпунцова Елена Вячеславовна²

lev86@bmstu.ru

SPIN-код: 3500-4160

¹ НИТУ МИСИС, Москва, Россия² МГТУ им. Н.Э. Баумана, Москва, Россия

Аннотация. Рассмотрено влияние роста мирового энергопотребления на изменение экологического равновесия в природе. Цифровизация растениеводства требует создания эффективных систем распознавания болезней растений. Современные исследования ориентированы на разработку легковесных, интерпретируемых моделей, устойчивых к изменчивым условиям съемки и пригодных для работы на устройствах с ограниченными ресурсами.

Ключевые слова: распознавание болезней растений, глубокое обучение, многозадачная классификация, ExG, объяснимый ИИ, легковесные модели

Leaf disease recognition using deep learning methods

Muthana Ali Salem Ali¹

m2112648@edu.misis.ru

Lyapuntsova Elena Vyacheslavovna²

lev86@bmstu.ru

SPIN-code: 3500-4160

¹ NUST MISIS, Moscow, Russia² BMSTU, Moscow, Russia

Abstract. Context & Relevance: Digital agriculture requires efficient plant disease recognition from leaf images. Current research focuses on lightweight, explainable models robust to field conditions.

Keywords: plant disease recognition, deep learning, multi-task classification, ExG, explainable AI, lightweight models

Введение. Развитие точного земледелия требует создания легких и эффективных алгоритмов для диагностики болезней растений по снимкам, сделанным в сложных полевых условиях. Современные исследования показывают, что даже компактные нейросети могут достигать высокой точности. Однако у многих моделей есть общее ограничение: они часто обучаются на идеализированных данных со статичным фоном и освещением, что приводит к переобучению и плохой работе в реальности [1–4]. В данной работе предлагается подход, сочетающий следующее. Физиологически мотивированный ввод: Использование индекса зелени (ExG) для выделения листа на фоне и компенсации изменчивого освещения. ExG интегрируется в зеленый канал изображения, что сохраняет совместимость с предобученной моделью EfficientNet-B0 [5].

Многозадачное обучение: модель одновременно учится распознавать вид растения и заболевание. Это работает как регуляризация, улучшая обобщающую способность модели. Синтетическое расширение данных: генерация искусственных поражений для увеличения разнообразия обучающей выборки без трудоемкой ручной разметки. Главная гипотеза заключается в том, что сочетание этих методов позволит создать более стабильную, интерпретируемую и легкую модель, устойчивую к изменению условий съемки и пригодную для работы на краевых устройствах [2, 6]. Цель исследования — экспериментально проверить эту гипотезу, разработав и оценив иерархическую сеть для распознавания болезней, ориентированную на практическое применение [4, 7].

Методы и материалы; результаты. Эмпирическая база исследования — открытый набор данных New Plant Diseases Dataset (Augmented). Для контроля распределения все изображения были переиндексированы в единую таблицу и стратифицированно разделены на обучающую, валидационную и тестовую выборки. Для ускорения экспериментов использовался поднабор из шести наиболее представленных классов заболеваний, ограниченный 120 изображениями на класс [4, 7].

В качестве базовой архитектуры использовалась предобученная на ImageNet модель EfficientNet-B0. Базовая модель имела одну классификационную голову для определения болезни. Предлагаемая HiP²-Net сохраняла ту же основу, но включала две головы: для определения болезни и вида растения, что обеспечивает регуляризацию и улучшает обобщение.

Процедура подготовки данных включала вычисление индекса зелени (ExG) для выделения листа и компенсации изменений освещения. ExG мягко интегрировался в зеленый канал RGB-изображения. Для аугментации данных применялись геометрические и цветовые преобразования, а также синтетические пятна для моделирования поражений [1, 7].

Обучение проводилось в два этапа с использованием оптимизатора AdamW. На первом этапе обучались только головы модели, на втором — дополнительно размораживались последние сверточные слои. Для оценки модели использовались точность, precision, recall, F1-мера и матрица ошибок. Для интерпретации результатов применялись карты вклада на основе интегрированных градиентов.

Все эксперименты проводились в контролируемых условиях с фиксацией случайных зерен для обеспечения воспроизводимости результатов [1, 3].

Обсуждение полученных результатов. Результаты полностью подтвердили основную гипотезу: включение индекса ExG в зеленый канал снизило зависимость модели от фона и повысило устойчивость к изменению условий съемки. Многозадачное обучение (определение вида растения и болезни) улучшило обобщающую способность модели, что отразилось в росте метрик точности и F1. Двухэтапное обучение с частичным размораживанием EfficientNet-B0 позволило достичь точности 0,9306 против 0,8750 у базовой модели.

Сравнение с литературными данными показывает, что наш подход согласуется с современными тенденциями: усиление информативных каналов (ExG)

дало эффект, аналогичный механизмам внимания, но без усложнения архитектуры; многозадачность стабилизировала признаки и предотвратила переобучение; визуализация с помощью интегрированных градиентов подтвердила, что модель фокусируется на ключевых областях листа; ограничением работы стала трудность дифференциации слабых симптомов заболеваний внутри одного вида растений. Однако предложенное решение демонстрирует оптимальное соотношение простоты, эффективности и интерпретируемости, соответствуя тренду на создание практических моделей для полевых условий.

Заключение. Эксперимент подтвердил все гипотезы. Встраивание индекса ExG снизило зависимость от фона и освещения. Многозадачное обучение улучшило обобщающую способность модели. Двухэтапное обучение с частичной разморозкой слоев повысило точность до 0,9306 против 0,8750 у базовой модели. Визуализация показала, что модель фокусируется на физиологически значимых областях листа.

Научная ценность работы заключается в практической комбинации трех воспроизводимых методов: усиление зеленого канала через ExG; многозадачное обучение; частичное размораживание слоев. Это улучшает устойчивость классификатора без существенного роста вычислительных затрат. Перспективы применения включают: расширение на большее число культур и заболеваний; интеграцию в мобильные приложения и облачные сервисы; развитие в направлениях доменной адаптации, квантизации и сегментации.

Ограничения: использовался сокращенный датасет (6 классов, ≤ 120 изображений на класс); синтетические аугментации могут вносить артефакты; отсутствие внешнего тестового бенчмарка; аппаратные ограничения не позволили расширить эксперименты.

Список источников

- [1] Chen R., Qi H., Liang Y., Yang M. Identification of plant leaf diseases by deep learning based on channel attention and channel pruning. *Frontiers in Plant Science*, 2022, no. 13. <https://doi.org/10.3389/fpls.2022.1023515>
- [2] El Fatimi E.H. Leaf diseases detection using deep learning methods. URL: <https://arxiv.org/abs/2501.00669> (accessed 10.12.2025).
- [3] Gupta A., Garg P., Thakur D., Palit R. Plant Disease Detection Using Deep Learning. *Proceedings of the Fifth Congress on Intelligent Systems. Lecture Notes in Networks and Systems*, 2025, vol. 1277, pp. 373–384.
- [4] Russel N.S., Selvaraj A. Leaf species and disease classification using multiscale parallel deep CNN architecture. *Neural Computing and Applications*, 2022, vol. 34, pp. 19217–19237.
- [5] Shoaib M., Shah B., El-Sappagh S., Ali A. et al. An advanced deep learning models-based plant disease detection: a review of recent research. *Plant Bioinformatics*, 2023, vol. 14. <https://doi.org/10.3389/fpls.2023.1158933>
- [6] Sundhar S., Sharma R., Maheshwari P., Kumar S.R., Kumar T.S. Enhancing Leaf Disease Classification Using GAT-GCN Hybrid Model. URL: <https://arxiv.org/html/2504.04764v1> (accessed 10.12.2025).
- [7] Romiyal G., Selvarajah T., Roshan G., Kayathiri M. et al. Past, present and future of deep plant leaf disease recognition. *Computers and Electronics in Agriculture*, 2025, vol. 234, art. no. 110128. <https://doi.org/10.1016/j.compag.2025.110128>