

DOI: 10.12731/2658-6649-2021-13-3-103-118

УДК 632.08+004.8

КЛАССИФИКАЦИЯ ВНЕКОРНЕВЫХ ЗАБОЛЕВАНИЙ ЯБЛОНЕВЫХ КУЛЬТУР МЕТОДАМИ КОМПЬЮТЕРНОГО ЗРЕНИЯ

С.Н. Терещенко, А.А. Перов, А.Л. Осипов

Цель. Разработка модели сверточной нейронной сети для определения внекорневых заболеваний яблонь по фотографиям листьев с мобильного телефона.

Методы и материалы исследования. Материалом для исследований послужили размеченные изображения с различными видами внекорневых заболеваний яблони, опубликованные в открытом доступе платформы Kaggle. Методы исследования: теория проектирования и разработки информационных систем, программирования, методы аугментации и расширения датасетов для задач компьютерного зрения, методы настройки гиперпараметров обучения моделей нейронной сети.

Результаты. Яблоня (*Malus*) – многолетняя древесная культура рода *Malus*. Яблоки – основная плодовая культура России. Яблоня как плодовая культура распространена почти во всех странах умеренного климата, а в России она выращивается повсеместно – от северных регионов до юга [3]. Заболевания яблонь является одной из главных причин снижения урожайности садов по всему миру. Для профилактики и раннего предупреждения распространения заболеваний яблонь необходим инструмент в виде модели нейронной сети, позволяющей определить наличия заболевания по фотографии со смартфона листьев яблони. В работе использовались методы глубокого обучения сверточных нейронных сетей, а также концепция «transfer learning». На базе сети EfficientNet была обучена нейронная сеть, позволяющая с точностью 0,9842 по метрике F1-score определять наличие некорневых заболеваний яблонь по изображению листьев.

Заключение. Был подготовлен набор данных изображений листьев яблонь, включающий четыре класса, для эффективной классификации нейронной сетью. Два класса с признаками определенного заболевания яблони, один класс для наличия более одного заболевания и один класс для здоровых яблонь. Построена и обучена модель для решения задачи классификации по обнаружению болезни яблонь по изображениям листьев со смартфона.

Ключевые слова: нейронные сети; искусственный интеллект; яблоня; листья; заболевание растений; смартфон; глубинное обучение; аугментация

Для цитирования. Терещенко С.Н., Перов А.А., Осипов А.Л. Классификация внекорневых заболеваний яблоневых культур методами компьютерного зрения // *Siberian Journal of Life Sciences and Agriculture*. 2021. Т. 13, № 3. С. 103-118. DOI: 10.12731/2658-6649-2021-13-3-103-118

APPLE CROPS FOLIAR DISEASES CLASSIFICATION BY COMPUTER VISION METHODS

S.N. Tereshchenko, A.A. Perov, A.L. Osipov

Background. Development of a convolutional neural network model for detecting foliar diseases of apple trees from a photo of leaves from a mobile phone.

Materials and methods. The material for the research was taken images with various types of apple's foliar diseases, published in open access of the Kaggle platform. Research methods: theory of design and development of information systems, programming, methods of augmentation and extension of datasets for computer vision problems, methods of tuning hyperparameters for training neural network models.

Results. Apple (*Malus*) is a perennial tree of the genus *Malus*. Apples are the main fruit crop in Russia. The apple tree as a fruit crop is widespread in almost all temperate countries, in Russia it is grown everywhere – from the northern regions to the south [3]. Diseases of apple trees are one of the main reasons for the decline in the yield of orchards around the world. For the prevention and early warning of the spread of apple tree diseases, a tool is needed in the form of a neural network model that allows you to determine the presence of the disease from a smartphone photo of apple leaves. The methods of deep learning of convolutional neural networks, as well as the concept of “transfer learning”, were used in the work. A neural network was trained on the basis of the EfficientNet network, which allows to determine the presence of non-root diseases of apple trees by the image of leaves with an accuracy of 0.985 using the F1-score metric.

Conclusion. The data set of apple's leaves images, including four classes, was prepared for efficient classification by a neural network. Two classes with signs of a certain apple tree disease, one class for having more than one disease, and one class for healthy apple trees. A model was built and trained for classification task of detecting apple tree disease from images of leaves from a smartphone.

Keywords: neural networks; artificial intelligence; apple tree; leaves; plant disease; smartphone; deep learning; augmentation

***For citation.** Tereshchenko S.N., Perov A.A., Osipov A.L. Apple Crops Foliar Diseases Classification by Computer Vision Methods. Siberian Journal of Life Sciences and Agriculture, 2021, vol. 13, no. 3, pp. 103-118. DOI: 10.12731/2658-6649-2021-13-3-103-118*

Введение

Болезни растений оказывают неблагоприятное воздействие на сельскохозяйственное производство, что негативным образом влияет на продовольственную безопасность. Неправильная диагностика заболеваний для сельскохозяйственной культуры зачастую приводит к ошибочному использованию удобрений, что приводит к появлению устойчивых штаммов патогенов, а также к увеличению затрат на новые обработки и увеличению числа вспышек со значительными экономическими потерями и воздействием на окружающую среду [23]. Существует большое количество заболеваний, которые влияют на урожайность растений, что ведет к экономическим и экологическим потерям [1]. Поэтому диагностика заболеваний растений, дающая точный и своевременный результат, имеет первостепенное значение и является важной темой научных исследований в области информатизации сельского хозяйства.

Технологии искусственного интеллекта активно развиваются и широко применяются во многих отраслях химии, биологии, экономики и сельском хозяйстве [14, 22, 24]. Компьютерное зрение, как одна из составляющих элементов искусственного интеллекта, уже доказало свою эффективность в таких широко распространенных направлениях как распознавание лиц, автомобильных номеров и в задачах стегаанализа графических изображений. В данной статье рассмотрим использование технологий компьютерного зрения для определения заболеваний яблоневых культур.

Яблоня, выращиваемая в саду, может заболеть такими болезнями, как: пролиферация яблонь (ведьмина метла), горькая и плодовая гнили, млечный блеск, мозаичная болезнь, мозаичная кольчатость, мухосед, мучнистая роса, настоящий тутовник, обыкновенный рак, черный рак, отмирание ветвей, парша, подкожная вирусная пятнистость, ржавчина, сплюсненность веток, стекловидность плодов, цитоспороз, черная пятнистость. У каждого из этих заболеваний имеются свои характерные признаки. Например, какая-то из них может привести к разрушению древесины и коры, из-за чего яблоня начнет засыхать, а другая повреждает листовые пластины, что приводит к их пожелтению и облетанию и т. д. Отдельные заболевания приводят к тому, что у растения могут облететь все недозревшие плоды [2].

Разработка модели нейронной сети для смартфона, позволяющая распознавать наличие заболевания яблони по фотографиям листьев, представляется важной задачей для прикладных исследований в сельскохозяйственной отрасли.

Методы и материалы исследования

В данной работе исходным материалом для проведения научных исследований послужили размеченные изображения с различными видами заболеваний листьев яблони, которые опубликованы в открытом доступе на платформе Kaggle (kaggle.com). Методы исследования: теория проектирования и разработки информационных систем; программирования; аугментации и расширения датасетов для задач компьютерного зрения; алгоритмы настройки гиперпараметров обучения моделей нейронной сети.

Анализ существующих исследований

В последние годы компьютерное зрение и машинное обучение показали большой потенциал для ускорения диагностики болезней растений [10, 11, 12]. Разрабатываются методы компьютерного зрения, позволяющие использовать цифровые изображения симптомов, для классификации различных заболеваний сельскохозяйственных культур [4, 13]. Методы машинного обучения содержат традиционные алгоритмы компьютерного зрения: метод опорных векторов (англ. SVM); метод К-ближайших соседей (англ. KNN); алгоритм К-средних (англ. k-means) и другие. Модели диагностики заболеваний растений на основе глубинного обучения включают в себя использование различных технологий сверточных нейронных сетей (AlexNet, GoogleNet, VGGNet, ResNet). Во многих работах размер датасета был недостаточен, а многоклассовая классификация требовала трудоемкой настройки гиперпараметров для предотвращения переобучения [17]. В работе [15] применяются методы сегментации изображений, включающие алгоритмы К-средних, для обнаружения пораженных сегментов растений. В статье [6] определяются зеленые пиксели для маски на основе пороговых значений, которые вычисляются с помощью метода Otsu. В работе [18] была использована методика «transfer learning» на основе предобученной сети ResNet 50 с настройкой гиперпараметров. В работе [22] проанализированы различные методы сегментации, кластеризации и классификации с помощью применения пороговых значений изображений, метода К-средних и сверточных нейронных сетей. В работе [5] авторы используют предварительно обученную сверточную нейронную сеть с настройкой гиперпараметров. В работе [14] анализируется формирование датасета с изображениями заболеваний маниока для конкурса Kaggle

«iCassava 2019». В работе [1] используется матрица смежности GLCM и обработка результатов посредством бинаризации и мажоритарного голосования для определения заболеваний по фотографиям с беспилотного летательного аппарата. Работа [19] посвящена разработке модели распознавания болезней растений, основанной на классификации изображений листьев, с использованием глубоких сверточных сетей. Модель обучена распознавать 13 различных типов заболеваний растений по фотографии листьев.

В работе [12] предлагается подход к идентификации болезней листьев яблони, основанный на глубоких сверточных нейронных сетях, который включает в себя генерацию достаточного количества изображений с патологиями и разработку новой архитектуры глубокой сверточной нейронной сети на основе AlexNet. В рамках тестового набора hold-out экспериментальные результаты показывают, что предложенный подход идентификации заболеваний на основе сверточной нейронной сети достигает общей точности 97,62%.

Наличие смартфонов практически у каждого человека и достижения в области глубокого машинного обучения открывают новые перспективы в классификации болезней растений. Например, мобильное приложение Plantix (plantix.net) позволяет пользователям по изображениям листьев выявлять патологию. Приложение разработано компанией PEAT, немецким стартапом AgTech. Приложение может обнаруживать более 400 различных заболеваний для 30 видов популярных культур.

В работе [8] на основе собственного датасета с заболеваниями растений проводились эксперименты с сямской нейронной сетью. Точность в 90% была достигнута при обнаружении черной гнили и хлороза на виноградных листьях.

Данная работа использует современные технологии для классификации внекорневых заболеваний яблони при помощи компьютерного зрения и опирается на описанные выше методы и подходы.

Результаты исследования

Открытый датасет представляет собой более 3600 изображений [16]. Изображения размечены на 4 класса. Два класса под заболевания (парша, кедровая ржавчина), третий класс, включающий более одного заболевания, и четвертый класс для здоровых яблонь. Изображения различных размеров представлены в формате «jpg». К датасету прилагается файл в формате «csv» с разметкой фотографий. Для обучения использовался фреймворк PyTorch. В работе решается задача классификации заболеваний яблонь на четыре класса. Пример изображений датасета представлен на рисунке 1.

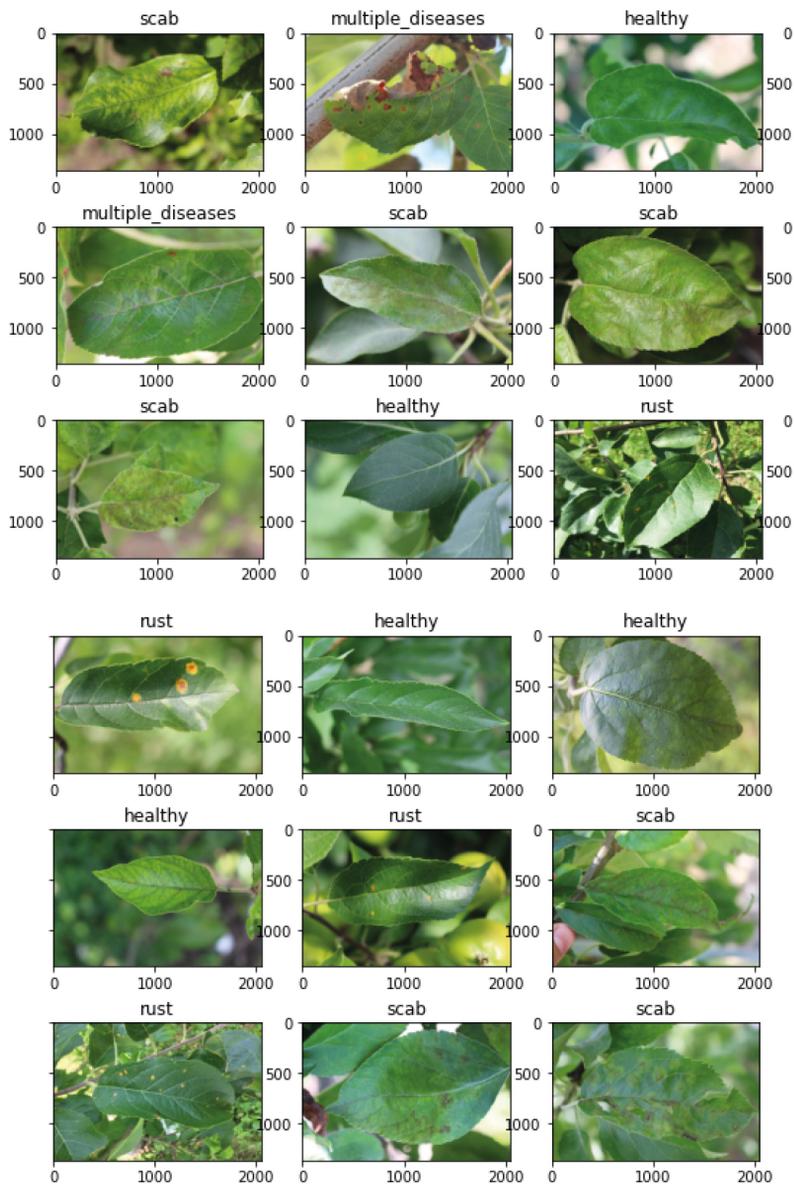


Рис. 1. Размеченные изображения из датасета

Для задачи классификации в работе была использована концепция «transfer learning». Если современные нейронные сети используют анализ простейших графических примитивов на нижних слоях, то концепция «transfer learning» зарекомендовала себя уже на многих более сложных задачах [9, 21]. Предобученная на большом количестве изображений нейронная сеть дает преимущество в стоимости и скорости обучения. Модель начинает процесс обучения не с нуля, а с заданных паттернов, которые были получены при решении другой задачи, которая сходна по своей природе с решаемой. Предварительно обученная модель обучается на большом эталонном наборе данных для решения задачи, аналогичной классификации внекорневых заболеваний яблони. Была выбрана предобученная модель EfficientNet-B7.

Ключевой особенностью сверточной нейронной сети семейства EfficientNet является то, что она использует масштабирование и балансирование между собой глубины и ширины, а также разрешение изображений сети. Эксперименты по увеличению масштаба по каждому из измерений показывают следующие результаты.

Увеличение ширины повышает количество каналов в изображении, что позволяет определить более детализированные признаки. При увеличении ширины растет и сложность изучения комплексных признаков, что увеличивает время обучения.

Увеличение глубины (количества слоев сети) позволяет выявлять более сложные признаки. Однако значительно затрудняется обучение сети и имеется ограничение на прирост эффективности (например, сеть ResNet-100 имеет такую же точность, как ResNet-1000).

Увеличение разрешения (изображения) позволяет находить более мелкие структуры за счет дополнительных деталей изображения, но при этом увеличиваются ресурсы на обучение и имеется ограничение на прирост эффективности [7].

В то же время, балансирование масштабированием по каждому из измерений (ширина, глубина и разрешение) приводит к приросту точности при незначительном росте ресурсов на обучение. На рисунке 2 показаны последовательно сети [20]:

1. Базовая модель, с заданным количеством слоев (англ. layer), каналов (англ. channels).
2. Расширение количества каналов (ширины, англ. wider).
3. Увеличение глубины модели (англ. deeper).
4. Повышения разрешения изображения (англ. higher resolution).

5. Одновременным расширением масштаба по ширине, глубине и разрешению.

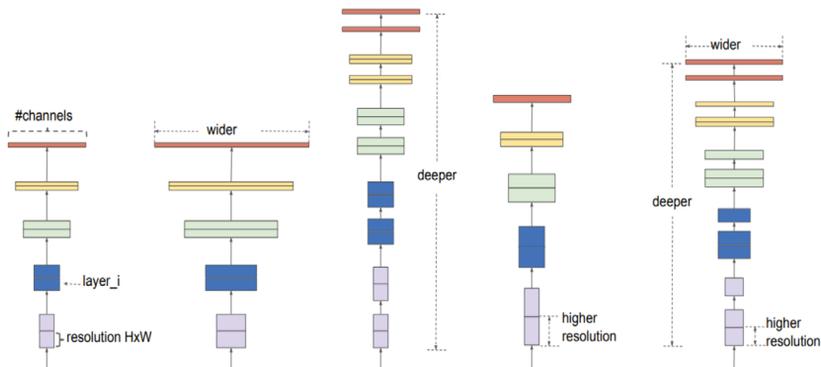


Рис. 2. Масштабирование нейронной сети

Семейство EfficientNet имеет классы с постепенным увеличением коэффициентов усложнения сети, начиная с базовой EfficientNet-B0. В статье применялась предобученная на базе ImageNet сеть EfficientNet-B7.

Для увеличения общего количества датасета была использована технология аугментации изображений. Изображения для обучения были изменены до размеров 560×560 пикселей, а затем из этого изображения случайно выбирался квадрат размером 512×512 пикселей. Была применена технология зеркалирования по вертикальной центральной оси и поворот изображения до 15 градусов в обе стороны. Использован прием “вырезки” небольших блоков из изображения. Затем использовалась техника изменения яркости и добавления отблесков на изображениях. Методы аугментации данных часто используются вместе с традиционными алгоритмами машинного обучения или алгоритмами глубокого обучения для повышения точности классификации. Для аугментации данных использовалась библиотека Albumentations. Пример применения к изображению методов аугментации показан на рисунке 3.

В работе использовался метод стохастического градиентного спуска (SGD). В качестве настройки гиперпараметра шага обучения было подобрано опытным путем значение « $\eta=0.003$ ». В качестве функции потерь была выбрана перекрестная энтропия (CrossEntropyLoss) с мультиклассовой функцией оценки логарифмических потерь. В качестве алгоритма оптимизации был использован Адам.

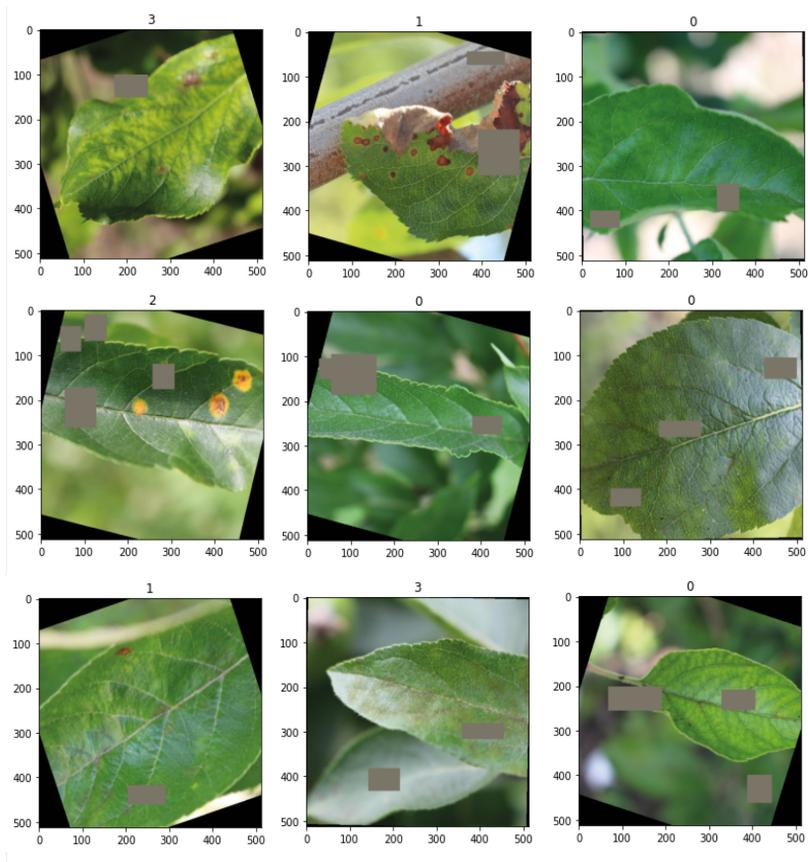


Рис. 3. Аугментация изображения листьев яблони

Датасет был разделен на три выборки: обучающая (состоит из 70% изображений); проверочная (состоит из 15% изображений); тестовая (состоит из 15% изображений). Использовалась предварительно обученная модель EfficientNet-B7, которая включала механизм переобучения последних слоев.

Результаты научных исследований показали, что точность классификации на тестовой выборке по метрике F1-score оказалась равной 0,9842, на проверочной оказалась равной 0,9896, а на обучающей выборке оказалась равной 0,9938.

Обсуждение

Для предотвращения экономического ущерба из-за падения урожайности нужно знать точный диагноз заболеваний яблоневых культур. Ранняя профилактика заболеваний яблони по фотографиям листьев крайне важна для предотвращения проблем, связанных с решением продовольственной программы.

Интеллектуальная система компьютерного зрения, предназначенная для выявления внекорневых заболеваний яблони по визуальным симптомам, могла бы оказать большую помощь в решении продовольственной программы. Учитывая широкое распространение у садоводов смартфонов с возможностью выхода в интернет и наличием фотокамеры, подобная система может повсеместно применяться на садовых посадках по всему миру. Это не только приведет к улучшению качества и скорости постановки диагноза заболевания, поскольку хорошо обученные глубинные нейронные сети могут выполнять эти избыточные задачи не хуже людей, но и к повышению производительности садовых хозяйств. Данная работа основана на проблеме машинной классификации внекорневых заболеваний яблони с использованием методов компьютерного зрения. Разработанная модель рекомендуется для практического применения в садовых хозяйствах, которые выращивают яблоневые культуры.

Заключение

Заболевания представляют собой серьезную угрозу для урожайности яблоневых культур. В работе демонстрируется техническая осуществимость глубокого обучения с использованием сверточного нейросетевого подхода для автоматической диагностики внекорневых заболеваний с помощью классификации изображений. Используя общедоступный набор данных из более 3600 изображений больных и здоровых листьев яблони, глубокая сверточная нейронная сеть обучается классифицировать наличие заболеваний по двум отдельным видам и одному с наличием множественных заболеваний, достигая точности распознавания более 98,4%. В статье был исследован подход применения методов глубокого обучения для автоматической классификации и обнаружения внекорневых заболеваний яблони по изображениям листьев. Модель позволила проводить классификацию внекорневых заболеваний яблоневых культур методами компьютерного зрения. Была описана методика подготовки изображений для обучения и валидации, аугментация, процедура обучения сверточной нейронной сетью и настройкой гиперпараметров обучения.

Информация о конфликте интересов. Отсутствие конфликта интересов.
Информация о спонсорстве. Исследование не имело спонсорской поддержки.

Список литературы

1. Тутьгин В.С., Лелюхин Д.О. Система диагностики заболеваний листьев растений по фотоизображениям, полученным с помощью БПЛА // Материалы научной конференции «Неделя науки СПбПУ». Санкт-Петербург, 19–24 ноября 2018.
2. Яблоки, АГРАРИЙ. <https://agrarii.com/jablonja/> (дата обращения: 20.03.2021).
3. Яблоки, АгроWIKI. <https://agrostrana.ru/wiki/305> (дата обращения: 20.03.2021).
4. Amara J., Bouaziz B., Algergawy A. A Deep Learning-based Approach for Banana Leaf Diseases Classification // Conference Datenbanksysteme für Business, Technologie und Web. January 2017. http://btw2017.informatik.uni-stuttgart.de/slidesandpapers/E1-10/paper_web.pdf (дата обращения: 20.03.2021).
5. Reyes A.K., Caicedo J.C., Camargo J.E. Fine-tuning Deep Convolutional Networks for Plant Recognition // Conference and Labs of the Evaluation Forum - CLEF 2015. <http://ceur-ws.org/Vol-1391/121-CR.pdf>
6. Fast and Accurate Detection and Classification of Plant Diseases / Al-Hiary H., Bani-Ah Mad S., Reyalat M., Braik M., ALRahamneh Z. // International Journal of Computer Applications (0975 – 8887). March 2011. Vol. 17, No. 1. P. 31-38. <https://doi.org/10.5120/2183-2754>
7. Ginsburg I. Исследуем архитектуры сверточных нейронных сетей с помощью fast.ai. <https://proglib.io/p/issleduem-arhitektury-svertochnyh-neyronnyh-setey-s-pomoshchyu-fast-ai-2020-12-28> (дата обращения: 20.03.2021).
8. Goncharov P., Nechaevskiy A., Ososkov G., Uzhinskiy A. Disease Detection on the Plant Leaves by Deep Learning // Papers from the XX International Conference on Neuroinformatics. October 8-12, 2018, Moscow, Russia. In book: Advances in Neural Computation, Machine Learning, and Cognitive Research II. pp.151-159. https://doi.org/10.1007/978-3-030-01328-8_16
9. Identification and Recognition of Rice Diseases and Pests Using Convolutional Neural Networks / Rahman C. R., Arko P. S., Ali M. E., Khan M. A. I., Apon S. H., Nowrin F., Wasif A. // Biosystems Engineering. June 2020. Vol. 194. P. 112-120. <https://doi.org/10.1016/j.biosystemseng.2020.03.020>
10. Khirade S.D., Patil A.B. Plant Disease Detection Using Image Processing // 2015 International Conference on Computing Communication Control and Automation. 2015. P. 768-771. <https://doi.org/10.1109/ICCUBEA.2015.153>

11. Lee D., Back C. et al. Biological Characterization of *Marssonina coronaria* Associated with Apple Blotch Disease // *Mycobiology*. 2011. Vol. 39. No 3. <https://doi.org/10.5941/MYCO.2011.39.3.200>
12. Liu B., Zhang Y., He D., Li Y.: Identification of apple leaf diseases based on deep convolutional neural networks // *Symmetry*. 2017. Vol. 10, No 1, 11. <https://doi.org/10.3390/sym10010011>
13. Mahlein A. Plant Disease Detection by Imaging Sensors – Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping // *Computational Intelligence and Neuroscience*, June 2016. <https://doi.org/10.1155/2016/3289801>
14. Mwebaze E., Gebru T., Frome A., Nsumba S., Tusubira J. iCassava 2019 Fine-Grained Visual Categorization Challenge. <https://arxiv.org/abs/1908.02900> (accessed 20.03.2021).
15. Phadikar S., Sil J. Rice Disease Identification Using Pattern Recognition Techniques // 2008 11th International Conference on Computer and Information Technology. J24-27, Dec. 2008. <https://doi.org/10.1109/ICCITECHN.2008.4803079>
16. Plant Pathology 2020 - FGVC7, Kaggle. <https://www.kaggle.com/c/plant-pathology-2020-fgvc7/overview> (accessed 20.03.2021).
17. Revathi P., Hemalatha M. Classification of Cotton Leaf Spot Diseases Using Image Processing Edge Detection Techniques // *International Conference on Emerging Trends in Science, Engineering and Technology (INCOSET)*. 13-14 Dec. 2012. <https://doi.org/10.1109/INCOSET.2012.6513900>
18. Sagar A., J Dheeba J. On Using Transfer Learning For Plant Disease Detection. <https://www.biorxiv.org/content/10.1101/2020.05.22.110957v1.full> (accessed 20.03.2021).
19. Sladojevic S., Arsenovic M., Anderla A., Culibrk D. Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification // *Computational Intelligence and Neuroscience*, June 2016. P. 1-11. <https://doi.org/10.1155/2016/3289801>
20. Tan M., Le Q. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. <https://arxiv.org/pdf/1905.11946.pdf> (accessed 20.03.2021).
21. Tea leaf diseases recognition using neural network ensemble / Karmokar B. C, Ullah M. S., Siddiquee Md. K., Alam K. Md. R. // *International Journal of Computer Applications*. March 2015. Vol. 114, No. 17. P. 27-30. <http://dx.doi.org/10.5120/20071-1993>
22. Tete T. N., Kamlu S. Plant Disease Detection Using Different Algorithms // *Proceedings of the Second International Conference on Research in Intelligent and Computing in Engineering*. June 2017. Vol. 10. P. 103–106. <https://doi.org/10.15439/2017R24>

23. Thapa R., Snavely N., Belongie S., Khan A. The Plant Pathology 2020 challenge dataset to classify foliar disease of apples. <https://arxiv.org/pdf/2004.11958.pdf> (accessed 20.03.2021).
24. Osipov A.L., Bobrov L.K. The use of statistical models of recognition in the virtual screening of chemical compounds // Automatic Documentation and Mathematical Linguistics. 2012. Vol. 46, No. 4. P. 153-158. <https://link.springer.com/article/10.3103/S0005105512040024>

References

1. Tutygin V.S., Lelyukhin D.O. Sistema diagnostiki zabolevaniy list'ev rasteniy po fotoizobrazheniyam, poluchennym s pomoshch'yu BPLA [A system for diagnosing plant leaf diseases based on photographs obtained with the help of BPLA]. *Materialy nauchnoy konferentsii «Nedelya nauki SPbPU»*. Sankt-Peterburg, 19–24 noyabrya 2018 [Materials of the scientific conference “Science Week of SPbPU”. St. Petersburg, 19-24 November 2018].
2. Apples, *AGRARIJ*. <https://agrarii.com/jablonja/> (accessed 20.03.2021).
3. Apples, *AgroWIKI*. <https://agrostrana.ru/wiki/305> (accessed 20.03.2021).
4. Amara J., Bouaziz B., Algergawy A. A Deep Learning-based Approach for Banana Leaf Diseases Classification. *Conference Datenbanksysteme für Business, Technologie und Web. January 2017*. http://btw2017.informatik.uni-stuttgart.de/slidesandpapers/E1-10/paper_web.pdf (дата обращения: 20.03.2021).
5. Reyes A.K., Caicedo J.C., Camargo J.E. Fine-tuning Deep Convolutional Networks for Plant Recognition. *Conference and Labs of the Evaluation Forum - CLEF 2015*. <http://ceur-ws.org/Vol-1391/121-CR.pdf>
6. Al-Hiary H., Bani-Ah Mad S., Reyalat M., Braik M., ALRahamneh Z. Fast and Accurate Detection and Classification of Plant Diseases. *International Journal of Computer Applications (0975 – 8887)*, March 2011, vol. 17, no. 1, pp. 31-38. <https://doi.org/10.5120/2183-2754>
7. Ginsburg I. Exploring convolutional neural network architectures with fast.ai. <https://proglib.io/p/issleduem-arhitektury-svertochnyh-neyronnyh-setey-s-pomoshchyu-fast-ai-2020-12-28> (accessed 20.03.2021).
8. Goncharov P., Nechaevskiy A., Ososkov G., Uzhinskiy A. Disease Detection on the Plant Leaves by Deep Learning. *Papers from the XX International Conference on Neuroinformatics. October 8-12, 2018, Moscow, Russia. Advances in Neural Computation, Machine Learning, and Cognitive Research II*. pp.151-159. https://doi.org/10.1007/978-3-030-01328-8_16
9. Rahman C. R., Arko P. S., Ali M. E., Khan M. A. I., Apon S. H., Nowrin F., Wasif A. Identification and Recognition of Rice Diseases and Pests Using Con-

- volutional Neural Networks. *Biosystems Engineering*, June 2020, vol. 194, pp. 112-120. <https://doi.org/10.1016/j.biosystemseng.2020.03.020>
10. Khirade S.D., Patil A.B. Plant Disease Detection Using Image Processing. *2015 International Conference on Computing Communication Control and Automation*. 2015, pp. 768-771. <https://doi.org/10.1109/ICCUBEA.2015.153>
 11. Lee D., Back C. et al. Biological Characterization of Marssonina coronaria Associated with Apple Blotch Disease. *Mycobiology*, 2011, vol. 39, no. 3. <https://doi.org/10.5941/MYCO.2011.39.3.200>
 12. Liu B., Zhang Y., He D., Li Y.: Identification of apple leaf diseases based on deep convolutional neural networks. *Symmetry*, 2017. vol. 10, no. 1, 11. <https://doi.org/10.3390/sym10010011>
 13. Mahlein A. Plant Disease Detection by Imaging Sensors – Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping. *Computational Intelligence and Neuroscience, June 2016*. <https://doi.org/10.1155/2016/3289801>
 14. Mwebaze E., Gebru T., Frome A., Nsumba S., Tusubira J. iCassava 2019 Fine-Grained Visual Categorization Challenge. <https://arxiv.org/abs/1908.02900> (accessed 20.03.2021).
 15. Phadikar S., Sil J. Rice Disease Identification Using Pattern Recognition Techniques. *2008 11th International Conference on Computer and Information Technology*. J24-27, Dec. 2008. <https://doi.org/10.1109/ICCITECHN.2008.4803079>
 16. Plant Pathology 2020 - FGVC7, Kaggle. <https://www.kaggle.com/c/plant-pathology-2020-fgvc7/overview> (accessed 20.03.2021).
 17. Revathi P., Hemalatha M. Classification of Cotton Leaf Spot Diseases Using Image Processing Edge Detection Techniques. *International Conference on Emerging Trends in Science, Engineering and Technology (INCOSET)*. 13-14 Dec. 2012. <https://doi.org/10.1109/INCOSET.2012.6513900>
 18. Sagar A., J Dheeba J. On Using Transfer Learning For Plant Disease Detection. <https://www.biorxiv.org/content/10.1101/2020.05.22.110957v1.full> (accessed 20.03.2021).
 19. Sladojevic S., Arsenovic M., Anderla A., Culibrk D. Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification. *Computational Intelligence and Neuroscience*, June 2016. P. 1-11. <https://doi.org/10.1155/2016/3289801>
 20. Tan M., Le Q. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. <https://arxiv.org/pdf/1905.11946.pdf> (accessed 20.03.2021).
 21. Karmokar B. C, Ullah M. S., Siddiquee Md. K., Alam K. Md. R. Tea leaf diseases recognition using neural network ensemble. *International Journal of Computer Applications*, March 2015, vol. 114, no. 17, pp. 27-30. <http://dx.doi.org/10.5120/20071-1993>

22. Tete T. N., Kamlu S. Plant Disease Detection Using Different Algorithms. *Proceedings of the Second International Conference on Research in Intelligent and Computing in Engineering*, June 2017, vol. 10, pp. 103–106. <https://doi.org/10.15439/2017R24>
23. Thapa R., Snavely N., Belongie S., Khan A. The Plant Pathology 2020 challenge dataset to classify foliar disease of apples. <https://arxiv.org/pdf/2004.11958.pdf> (accessed 20.03.2021).
24. Osipov A.L., Bobrov L.K. The use of statistical models of recognition in the virtual screening of chemical compounds. *Automatic Documentation and Mathematical Linguistics*, 2012, vol. 46, no. 4, pp. 153–158. <https://link.springer.com/article/10.3103/S0005105512040024>

ДАННЫЕ ОБ АВТОРАХ

Терешенко Сергей Николаевич, заведующий кафедрой «Прикладная информатика», доцент, кандидат технических наук
ФГБОУ Новосибирский государственный университет экономики и управления
ул. Каменская, 56, г. Новосибирск, Новосибирская область, 630099,
Российская Федерация
sg12@ngs.ru

Перов Артём Андреевич, ассистент кафедры «Информационная безопасность»
ФГБОУ ВО «Московский политехнический университет»
ул. Б. Семеновская, 38, г. Москва, 107023, Российская Федерация
perov_artem@inbox.ru

Осипов Александр Леонидович, доцент, кандидат технических наук
ФГБОУ Новосибирский государственный университет экономики и управления
ул. Каменская, 56, г. Новосибирск, Новосибирская область, 630099,
Российская Федерация
alosp@mail.ru

DATA ABOUT THE AUTHORS

Sergei N. Tereshchenko, Department Chair «Applied Informatics», Associate Professor, Candidate of Engineering Science
Novosibirsk State University of Economics and Management

56, Kamenskaya Str., Novosibirsk, 630099, Russian Federation

e-mail: sg12@ngs.ru

ORCID: <http://orcid.org/0000-0003-2309-8445>

SPIN-code: 2036-7632

Artem A. Perov, Assistant Professor of the Department «Information Security»

Moscow Polytechnic University

38, Bolshaya Semyonovskaya Str., Moscow, 107023, Russian Federation

perov_artem@inbox.ru

ORCID: 0000-0003-3401-7751

SPIN-code: 8592-6975

Alexander L. Osipov, Associate Professor, Candidate of Engineering Science

Novosibirsk State University of Economics and Management

56, Kamenskaya Str., Novosibirsk, 630099, Russian Federation

alosip@mail.ru

ORCID: 0000-0002-1809-9147

SPIN-code: 5697-8004

Scopus Author ID: 7202978114