

Использование цифровых интеллектуальных технологий для диагностики заболеваний хлебных злаков Кубани

Игорь Владимирович Ариничев

ФГБОУ ВО «Кубанский государственный университет», г. Краснодар, Россия

e-mail: iarinichev@gmail.com

Аннотация. В статье исследуется возможность применения методов машинного зрения для обнаружения и классификации грибных болезней пшеницы и риса по изображениям. Показано, что современные нейросетевые архитектуры способны качественно обнаруживать и классифицировать такие грибные болезни как желтая пятнистость, желтая и бурая ржавчины, пирикулярриоз и бурая пятнистость. Для рассмотренных моделей значения метрик классификации (accuracy, precision, recall, f1) колеблются в пределах от 0,95 до 0,99, что указывает на возможность использования цифровых интеллектуальных технологий для диагностики заболеваний злаков с точностью, не уступающей эксперту-фитопатологу. Используемая при этом архитектура нейронной сети достаточно легковесна, что делает возможным ее использования на мобильных устройствах.

Ключевые слова: машинное зрение; сверточная нейросеть; грибные болезни злаков; классификация болезней.

Для цитирования: Ариничев И. В. Использование цифровых интеллектуальных технологий для диагностики заболеваний хлебных злаков Кубани // Аграрный научный журнал. 2022. № 5. С. 70–73. <http://dx.doi.org/10.28983/asj.y2022i5pp70-73>.

AGRICULTURAL ENGINEERING

Original article

Using digital intelligent technologies for the diagnosis of cereals diseases in the Kuban

Igor V. Arinichev

Kuban State University, Krasnodar, Russia

e-mail: iarinichev@gmail.com.

Abstract. The article explores the possibility of using machine vision methods to detect and classify fungal diseases of wheat and rice by images. It is shown that modern neural network architectures are able to qualitatively detect and classify such fungal diseases as yellow spot, yellow and brown rust, pyriculariasis and brown spot. For the models considered, the values of classification metrics (accuracy, precision, recall, f1) range from 0.95 to 0.99, which indicates the possibility of using digital intelligent technologies to diagnose diseases of cereals with accuracy not inferior to an expert phytopathologist. The neural network architecture used in this case is quite lightweight, which makes it possible to use it on mobile devices.

Keywords: computer vision; convolutional neural network; fungal diseases; diseases classification.

For citation: Arinichev I. V. Using digital intelligent technologies for the diagnosis of cereals diseases in the Kuban // Agrarnyy nauchnyy zhurnal = Agrarian Scientific Journal. 2022;(5):70–73 (In Russ.). <http://dx.doi.org/10.28983/asj.y2022i5pp70-73>.

Введение. Пшеница, ячмень, рис и другие хлебные злаки являются ведущими культурами по площади возделывания в южном регионе России. Данные злаковые культуры подвержены комплексу вредоносных заболеваний, среди которых наиболее экономически значимые – возбудители бурой, желтой и стеблевой ржавчин (*Puccinia triticina* Erikss., *Puccinia striiformis* West. f. sp. *Tritici* Erikss. et Henn., *Puccinia graminis* Pers. f. sp. *tritici*), пириенофороза (*Pyrenophora tritici-repentis* (Died.) Drechsler), пирикулярриоза (*Pyricularia oryzae*). Болезни являются очень вредоносными и распространенными в мире и в России, особенно в ее южном регионе. Потери урожая пшеницы, ячменя во время эпифитотии данных болезней могут достигать 50–70 %, риса – до 40 %.

Для предотвращения угрозы потери урожая и обоснования проведения своевременных защитных мероприятий необходим эффективный фитосанитарный мониторинг. Понимание фитосанитарных условий полей позволяет не только предотвратить распространение болезней, но также является решающим фактором в ограничении использования фунгицидов и пестицидов при защите урожая, позволяя использовать препараты в нужном месте и в нужное время. Однако оценить благополучие агробиоценозов непросто и требует высокого уровня знаний от сельхозпроизводителей. Одно и то же заболевание может по-разному проявляться у разных видов растений и даже у разных сортов. Один и тот же симптом может быть результатом различных проблем, и эти проблемы могут сочетаться в рамках одного экземпляра растения. Даже дефицит питательных веществ может вызывать симптомы, сходные с симптомами некоторых грибных болезней.

Поэтому высокой практической ценностью и актуальностью является задача своевременной, точной и оперативной диагностики болезней злаков, которые могут быть решены с помощью цифровых интеллектуальных технологий, и машинного зрения в частности, получившего в последнее время широкое распространение [1–5].

Цель исследования – обосновать возможность использования методов машинного зрения в задаче идентификации грибных болезней пшеницы и риса.

Методика исследований. Материалом для исследования послужили образцы листьев пшеницы, пораженных ржавчинами и пятнистостями, полученные в результате исследований, проведенных в ФГБНУ ВНИИБЗР на опытных полях в 2019–2021 гг. В исследованиях были использованы 35 сортов озимой пшеницы, высеваемых на юге России и отличающихся по устойчивости к возбудителям бурой, желтой, стеблевой ржавчин и желтой пятнистости



листьев. Проведена их иммунологическая оценка по отношению к комплексу болезней в условиях искусственного инфекционного фона на полевом стационаре ФГБНУ ФНЦБЗР [6].

Сорта были ранжированы на группы: У – устойчивые, УУ – умеренно устойчивые, УВ – умеренно восприимчивые, В – восприимчивые. Из каждой группы были отобраны тестовые сорта, на которых в дальнейшем производились съемки поражения ржавчинами и желтой пятнистостью листьев.

Относительно бурой ржавчины это были сорта: У – Кавалерка, УУ – Собербаш, УВ – Сварог, В – Гром; желтой ржавчины: У – Граф, УУ – Ахмат, УВ – Фермер, В – Вольница; стеблевой ржавчины: У – Жаворонок, УУ – Хлебобор, УВ – Вольный Дон, В – Собербаш; желтой пятнистости листьев: У – Подарок Крыму, УУ – Ваня, УВ – Тимирязевка 150, В – Батко.

Съемки произведены от начала проявления болезни до массового ее развития. На каждом сорте было сделано порядка 100 фото.

В результате общий объем выборки по пшенице составил 5169 изображений, в том числе, бурая ржавчина – 227, желтая ржавчина – 1283, желтая пятнистость – 3659.

Для диверсификации исследования по культурам, авторами также была использована база болезней риса, находящихся в открытом доступе в сети [7]. Из выборки была исключен класс заболеваний «Hispa» как неактуальный для Юга России. В итоге выборочное распределение имело объем 4278 изображений, в том числе: бурая пятнистость – 1195, пирикулярриоз – 1595, здоровые растения – 1488.

В качестве методов исследования в работе использовались методы предобработки данных, методы обучения сверточных нейронных сетей.

Результаты исследований. Основной идеей, стоящей за сверточными нейронными сетями, является попытка приблизить работу сети к механизму работы зрения человека. В революционной работе Y. LeCun (1989) было замечено, что для достижения приемлемого результата классификации изображения нейронной сетью достаточно использовать не все связи между нейронами соседних слоев сети, а лишь малое их число [8]. Это, по сути, является простейшей моделью работы зрения, когда глаз, пытаясь отыскать какой-либо объект на изображении, последовательно фокусируется на разных его участках, а не на всем изображении сразу.

Математически подобная «фокусировка» взгляда соответствует операции свертки, которая, по сути, осуществляет соответствие паттернов области на изображении и некоторого искомого паттерна, в нашем случае, проявившейся болезни на листе пшеницы/риса. Объединяя подобные операции свертки в слои различными способами, можно получить различные архитектуры сверточных нейросетей, составляющими в настоящее время прочный фундамент современного компьютерного зрения и позволяющими успешно решать задачи из широкого спектра – классификации, кластеризации, сегментации и пр. (рис. 1).

В настоящей работе мы рассматриваем четыре хорошо зарекомендовавшие себя в соревнованиях ImageNet и относительно легковесные архитектуры – GoogleNet, ResNet-18, SqueezeNet-1.0, DenseNet-121. Результаты моделирования на валидационных выборках приведены в таблице.

Модели тренировались с помощью фреймворка PyTorch на валидационной выборке, которая включала 518 изображений листьев пшеницы и 429 изображений листьев риса. Лучший результат показала модель DenseNet-121, которая при сравнительно небольшом числе параметров неверно проклассифицировала болезни пшеницы лишь в 0,6 % случаев и риса в 4,4 % случаев. Учитывая несбалансированность классов в данных, дополнительно были рассчитаны метрики точности, полноты и F1-меры, вычисляемые по формулам [9]:

$$precision = \frac{TP}{TP + FP}, recall = \frac{TP}{TP + FN}, F1 = \frac{2 \times precision \times recall}{precision + recall},$$

где TP – верные срабатывания модели, FP – ложные срабатывания модели, FN – ложные пропуски модели.

Видно, что первая из этих метрик – «precision» – указывает на то, насколько мало модель ошибается, предсказывая наличие некоторой болезни. Вторая метрика – «recall» – показывает, насколько мало модель ошибается, говоря, что некоторой болезни на фотографии нет. F1 объединяет в себе точность и полноту, вычисляя их среднегармоническое значение. Учитывая высокие значения перечисленных метрик, можно сделать вывод, что модель не переобучилась на конкретный класс и корректно предсказывает результаты, даже болезни, с минимальным числом изображений.

Второй по качеству результат для пшеницы продемонстрировала модель SqueezeNet-1.0, с близким по качеству классификации результатом к лидеру DenseNet, но имея при этом почти в 10 раз меньше параметров, что позволит использовать ее локально, даже на мобильных устройствах, без использования облачных сервисов. По качеству классификации болезней риса, второе место заняла GoogleNet с более чем 94 % верных ответов на тестовых данных. Третьим по качеству оказалась ResNet-18, однако у нее уже существенно больше параметров, чем у остальных.

При рассмотрении матриц ошибок алгоритмов (рис. 2) видно, что для трех болезней пшеницы модель практически не ошибается и точно предсказывает класс «желтая ржавчина» допуская по одной ошибке для классов «бурая ржавчина» и «желтая пятнистость». В случае с болезнями риса было допущено 19 ошибок, обеспечи-




Рис. 1. Механизм работы сверточной нейронной сети



Итоговое сравнение показателей качества исследуемых архитектур

Модель Показатель	GoogleNet	ResNet-18	SqueezeNet-1.0	DenseNet-121
Пшеница				
Доля правильных ответов (ассигасу), %	97,8	98,2	98,6	99,4
Точность (precision), %	91,2	99	97,4	99,6
Полнота (recall), %	97	94,3	96,5	97
F1-мера	93,7	96,5	96,9	98,2
Число параметров, млн	5,6	11,1	0,7	6,9
Номер лучшей эпохи	8	6	9	9
Время обучения, с./эпоха	90	172	104	95
Рис				
Доля правильных ответов (ассигасу), %	94,2	93,4	94,1	95,6
Точность (precision), %	94,5	93,8	94,4	95,8
Полнота (recall), %	94,3	93,4	94,2	95,5
F1-мера	94,3	93,6	94,2	95,6
Количество параметров, млн	5,6	11,1	0,7	6,9
Номер лучшей эпохи	112	128	247	198
Время обучения, с./эпоха	92	165	134	95




Рис. 2. Матрицы ошибок DenseNet-121 для болезней пшеницы и риса

вая точность классификации на уровне 99,57 %, что в совокупности со значениями полноты 95,5 % и точности 95,8 % может считаться хорошим результатом, при условии, что на этапе обучения объекты валидационной выборки не использовались.

Заключение. В работе рассмотрена важная с прикладной точки зрения задача идентификации болезней злаков на основе методов машинного зрения. Рассмотрено три класса грибных болезней пшеницы (бурая ржавчина, желтая пятнистость), два класса грибных болезней риса (пирикулярриоз, бурая пятнистость) и класс здоровых растений. Проведен сравнительный анализ наиболее успешных и зарекомендовавших нейросетевых архитектур. Рассчитаны характеристики качества моделей. Показано, что лучшие результаты продемонстрировала модель DenseNet-121, обеспечив точность классификации свыше 95 %. При этом сама модель, имея 6,9 миллионов параметров, занимает на диске порядка 30-35 Мб, что делает возможным ее использование на мобильных устройствах. Такой вариант использования крайне важен для оперативного, точного и доступного обнаружения грибных болезней в процессе производства важнейших хлебных злаков.

Исследование выполнено при финансовой поддержке Кубанского научного фонда в рамках проекта № МФИ-20.1/75.

СПИСОК ЛИТЕРАТУРЫ

1. Boulent J., Foucher S., Th'eu J., and St-Charles P.-L. Convolutional neural networks for the automatic identification of plant diseases // *Frontiers in plant science*. 2019. vol. 10. DOI: <https://doi.org/10.3389/fpls.2019.00941>.
2. Polyanskikh S., Arinicheva I., Arinichev I., Volkova G. Autoencoders for semantic segmentation of rice fungal diseases // *Agronomy Research* 19(X), xxx-ccc, 2021. <https://doi.org/10.15159/ar.21.019>.
3. Ариничева И. В., Ариничев И. В., Полянских С. В., Волкова Г. В. Распознавание болезней риса с помощью современных методов компьютерного // *Аграрная наука*. 2021;(3):90-94. <https://doi.org/10.32634/0869-8155-2021-345-2-90-94>.
4. Ариничева И. В., Ариничев И. В. Современный математический инструментарий в решении проблем производства важнейших хлебных злаков на Кубани. Краснодар, 2021. 155 с.
5. Uzhinskiy A., Ososkov G., Goncharov P., Nechaevskiy A., Smetanin A. Oneshot learning with triplet loss for vegetation classification tasks // *Computer Optics* 2021; 45(4): 608-614. DOI: 10.18287/2412-6179-CO-856.



6. Матвеева И. П., Шумилов Ю. В., Волкова Г. В. Скрининг источников устойчивости к *Puccinia striiformis* West. среди сортообразцов пшеницы различного географического происхождения // Научное обеспечение агропромышленного комплекса: IX Всерос. конф. молодых ученых, посвящ. 75-летию В.М. Шевцова. Краснодар, 2016. С. 214–215.

7. Huy Do Rice Diseases Image Dataset: An image dataset for rice and its diseases. Режим доступа: <https://www.kaggle.com/minhhuy2810/rice-diseases-image-dataset>

8. LeCun Y., Bose, B., Denker J.S., Henderson D., Howard R. E., Hubbard W., Jackel L. D., Backpropagation Applied to Handwritten Zip Code Recognition // *Neural Computation*. 1989. 1(4):541-551. DOI:10.1162/neco.1989.1.4.541

9. Андриянов Н. А., Дементьев В. Е., Ташлинский А. Г. Обнаружение объектов на изображениях: от критериев Байеса и Неймана–Пирсона к детекторам на базе нейронных сетей EfficientDet // *Компьютерная оптика*. 2022. Т. 46. № 1. С. 139–159. DOI: 10.18287/2412-6179-CO-922.

REFERENCES

1. Boulent J., Foucher S., Th'eau J., and St-Charles P.-L. Convolutional neural networks for the automatic identification of plant diseases. *Frontiers in plant science*. 2019; 10. DOI: <https://doi.org/10.3389/fpls.2019.00941>.

2. Polyanskikh S., Arinicheva I., Arinichev I., Volkova G. Autoencoders for semantic segmentation of rice fungal diseases. *Agronomy Research* 19(X), xxx–ccc. 2021. <https://doi.org/10.15159/ar.21.019>.

3. Arinicheva I. V., Arinichev I. V., Polyanskikh S. V., Volkova G. V. Recognition of rice diseases using modern computer methods. *Agrarian science*. 2021; (3): 90-94. <https://doi.org/10.32634/0869-8155-2021-345-2-90-94>. (In Russ.).

4. Arinicheva I. V., Arinichev I. V. Modern mathematical tools in solving problems of the production of the most important cereals in the Kuban. *Krasnodar*, 2021. 155 p. (In Russ.).

5. Uzhinskiy A., Ososkov G., Goncharov P., Nechaevskiy A., Smetanin A. One-shot learning with triplet loss for vegetation classification tasks. *Computer Optics*. 2021; 45(4): 608-614. DOI: 10.18287/2412-6179-CO-856. (In Russ.).

6. Matveeva I. P., Shumilov Yu. V., Volkova G. V. Screening of sources of resistance to *Puccinia striiformis* West. among wheat varieties of different geographical origin. *Scientific support of the agro-industrial complex*. *Krasnodar*, 2016: 214-215.

7. Huy Do Rice Diseases Image Dataset: An image dataset for rice and its diseases. URL: <https://www.kaggle.com/minhhuy2810/rice-diseases-image-dataset>.

8. LeCun Y., Bose, B., Denker J. S., Henderson D., Howard R. E., Hubbard W., Jackel L. D., Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*. 1989; 1(4): 541-551. DOI:10.1162/neco.1989.1.4.541

9. Andriyanov N. A., Dementiev V. E., Tashlinskii A. G. Object detection in an image: from Bayesian and Neyman-Pearson criteria to detectors based on EfficientDet neural networks. *Computer Optics*. 2022; 46; 1: 139-159. DOI: 10.18287/2412-6179-CO-922. (In Russ.).

Статья поступила в редакцию 29.01.2022; одобрена после рецензирования 15.02.2022; принята к публикации 20.02.2022.

The article was submitted 29.01.2022; approved after reviewing 15.02.2022; accepted for publication 20.02.2022.

73

АГРАРНЫЙ НАУЧНЫЙ ЖУРНАЛ

5
2022

