

УДК 632.08+004.8

ОПРЕДЕЛЕНИЕ КОЛИЧЕСТВА КОЛОСЬЕВ НА ИЗОБРАЖЕНИЯХ ПШЕНИЧНЫХ ПОЛЕЙ МЕТОДАМИ КОМПЬЮТЕРНОГО ЗРЕНИЯ

© С. Н. Терещенко, А. Л. Осипов, Е. Д. Моисеева

*Новосибирский государственный университет экономики и управления,
630099, г. Новосибирск, ул. Каменская, 56
E-mail: alosip@mail.ru*

Для точного подсчёта количества колосьев по фотографиям пшеничного поля использовалась технология нейронных сетей. Применялись методы глубокого обучения свёрточных нейронных сетей во взаимодействии с методикой transfer learning. С помощью архитектуры EfficientDet произведено обучение нейронной сети, которая позволила с точностью 0,88012 на выборке по метрике F1-score с пороговым значением 0,6 (совпадение площади предсказанной разметки и фактической) определить количество колосьев пшеницы по графическим изображениям.

Ключевые слова: нейронные сети, искусственный интеллект, пшеница, колосья, урожайность, глубокое обучение, аугментация, детекция объектов.

DOI: 10.15372/AUT20220308

Введение. Пшеница — одна из самых культивируемых культур в мире. В 2019 г. мировое производство пшеницы достигло 762 млн тонн, большая часть которых была использована для потребления человеком [1]. Из-за высоких питательных компонентов, содержащихся в пшенице, таких как белок, витамины, клетчатка и фитохимические вещества, важность этой культуры крайне высока. Дальнейшее увеличение урожайности пшеницы в мире имеет решающее значение для долгосрочной продовольственной безопасности. Однако с 1990-х гг. темпы роста урожайности пшеницы замедлились. Понимание фенотипических признаков любой культуры (высота, цвет корней, цвет стеблей, количество ядер и т. д.) имеет жизненно важное значение для повышения скорости её роста и, в конечном счёте, урожайности [2].

Для уточнения урожайности пшеничных полей могут использоваться фотографии, что позволяет оценить плотность, размер, здоровье и зрелость пшеницы различных сортов. Однако точное определение количества колосьев на фотографиях пшеничного поля может быть визуальной сложной задачей. Более густые колосья могут перекрывать другие колосья пшеницы, и ветер может размыть изображения. Эти данные и другие факторы затрудняют идентификацию отдельных колосьев. Кроме того, внешний вид варьируется в зависимости от зрелости, цвета, генотипа и ориентации колоса пшеницы [3].

Появление на рынках беспилотных летательных аппаратов, камер и смартфонов сделало доступным возможность получать достаточное количество изображений с различных ракурсов пшеничного поля. Это позволяет производить подсчёт колосьев пшеницы по изображениям с помощью инструментов и алгоритмов глубокого обучения [4, 5].

Существует потребность в надёжной и точной компьютерной модели, способной подсчитывать количество колосьев пшеницы по цифровым изображениям. Эта модель принесёт пользу исследованиям в области фенотипирования и оценки объёма урожайности зерновых культур [6].

Цель работы состоит в применении модели свёрточной нейронной сети для определения количества колосьев пшеницы по изображениям посевов.

Материалы и методы исследования. В данной работе исходным материалом для проведения научных исследований послужили изображения (фотографии) полей пшеницы с размеченными координатами колосьев, опубликованные в открытом доступе на платформе Kaggle [5]. Методы исследования: искусственный интеллект, аугментация изображений для задач компьютерного зрения, алгоритмы настройки гиперпараметров для обучения моделей нейронной сети.

Анализ существующих исследований. Показатель количества колосьев является ключевым при оценке урожайности пшеницы, который также участвует при селекционной работе. В силу трудоёмкости ручного подсчёта возникают большие ошибки (погрешность измерения составляет примерно 10 %) [7]. Учитывая фактор временного окна цикла роста пшеницы, из-за чего подсчёт возможен только в течение небольшого периода зрелости, данная задача значительно усложняется, чтобы быть выполненной своевременно. До сих пор значительная часть наблюдений, имеющих решающее значение для их принятия по селекции растений, — это записанные вручную данные [2]. В настоящее время всё более распространёнными стали неинвазивные методы, основанные на анализе цифровых изображений [8].

В последние годы большое количество исследований проведено в различных сферах сельского хозяйства в направлении повышения урожайности различных культур за счёт применения цифровых технологий. Технологии искусственного интеллекта активно используются во многих отраслях химии, биологии, экономики, сельском хозяйстве, в том числе в промышленности и при анализе графических изображений [9–17]. Компьютерное зрение как одна из составляющих элементов искусственного интеллекта уже доказало свою эффективность в таких широко распространённых направлениях, как распознавание лиц и автомобильных номеров. В данной работе рассмотрим использование технологий компьютерного зрения для определения количества колосьев пшеницы при анализе графических изображений посевов.

С появлением современных крупномасштабных устройств сканирования изображений, таких как беспилотные летательные аппараты (БПЛА), спутники и мобильные камеры, появилась возможность значительно ускорить качественный и количественный анализ урожайности различных культур [18]. В [19] исследуется обнаружение и подсчёт банановых растений на основе глубокого обучения с использованием RGB-изображений высокого разрешения, полученных с беспилотного летательного аппарата.

Компьютерное зрение активно используется для диагностики болезней растений [20–22]. Классификация заболеваний растений на основе глубокого обучения включает в себя использование различных моделей свёрточных нейронных сетей (AlexNet, VGGNet, ResNet и др.). Во многих работах размер набора данных был недостаточен и приходилось использовать методы аугментации и расширения набора данных. Во избежание переобучения нейронной сети требовалась трудоёмкая настройка гиперпараметров [18]. В исследовании [23] используется подход сегментации объектов на изображениях, включающих алгоритмы К-средних для обнаружения поражённых сегментов растений. В [6] выделяются пиксели зелёного цвета для маски на основе пороговых значений методом Otsu. В работах [10–11] для задач классификации заболеваний маниоки и внекорневых заболеваний яблоневых культур была использована методика transfer learning на основе предобученной сети ResNet 50 с настройкой гиперпараметров. Transfer Learning (трансферное обучение) — это подраздел машинного обучения, целью которого является применение знаний, полученных из одной задачи, к другой целевой задаче. Например, знания, полученные при обучении классификации статей Википедии, можно использовать для решения задачи классификации текстов. Кроме того, можно использовать модель, обученную для решения классификации, например, автомобилей, чтобы распознавать тип птиц в небе как одну из задач компьютерного зрения. В исследовании [14] рассмотрены различные методы

сегментации, кластеризации и классификации с помощью применения пороговых значений изображений, метода K-средних и свёрточных нейронных сетей. В [24] используется предварительно обученная свёрточная нейронная сеть с настройкой гиперпараметров. В [1] анализируется формирование набора данных с изображениями заболеваний маниоки для конкурса Kaggle «iCassava 2019».

В данной работе используются современные подходы к проблеме детекции колосьев пшеницы с помощью компьютерного зрения с опорой на вышеописанные методы и подходы.

Результаты исследования. Доступный набор данных представляет собой более 3400 изображений [25]. Изображения пшеничных полей размечены на ограничивающие области. Координаты и размеры ограничивающей области (прямоугольника) определяют область нахождения колоса на изображении. Изображения размером 1024×1024 пикселей представлены в формате jpg. К набору данных прилагается файл в формате csv. Для обучения использовался пакет программ PyTorch. Решается задача детекции объектов. Изображения из набора данных представлены на рис. 1.

Для задачи детекции объектов в работе была использована концепция transfer learning. Если современные нейронные сети используют анализ простейших графических примитивов на нижних слоях, то эта концепция зарекомендовала себя уже во многих более сложных задачах, в том числе в задачах компьютерного зрения [14, 5]. Концепция transfer learning предполагает использование готовой нейронной сети, предобученной на большом количестве (несколько миллионов) схожих с задачей изображений. Предобученная сеть (модель) даёт преимущества в стоимости и скорости обучения. Была выбрана предобученная модель EfficientDet-D5 из семейства EfficientNet.

Общая архитектура EfficientDet в значительной степени соответствует парадигме одноступенчатых (one-stage) детекторов. За основу взята EfficientNet, предобученная на ImageNet, к ней добавлен слой со взвешенной двунаправленной пирамидой признаков (BiFPN), за которым идут классовая и блочная сети для генерации предсказаний класса объекта [26]. На рис. 2 показана архитектура EfficientDet.

Проведён тщательный анализ набора данных. Выявлена несбалансированность распределения количества колосьев на изображениях. График распределения количества размеченных колосьев представлен на рис. 3. По оси Q указано количество изображений по оси Q' — количество колосьев на одном изображении.

Для увеличения общего количества набора данных была использована технология аугментации изображений. Применена технология зеркалирования по вертикальной центральной оси и поворот изображения на 90° в обе стороны. Использовался приём «вырезки» небольших блоков из изображения, затем техника изменения яркости и добавления отблесков на изображениях. Методы аугментации данных часто применяются вместе с традиционными алгоритмами машинного обучения или алгоритмами глубокого обучения для повышения точности классификации. Для аугментации данных взята библиотека Albumentations. Пример применения к изображению методов аугментации показан на рис. 4. Из одного изображения (крайнее левое) создаются дополнительно три путём поворота и наложения световых шумов. С учётом аугментации объём выборки составил 10200 изображений.

В работе использовался метод стохастического градиентного спуска (SGD, Stochastic gradient descent) для обучения нейронной сети. В качестве настройки гиперпараметра шага (скорости спуска) подобрано опытным путём значение $lr = 0,0002$. Для функции потерь был выбран показатель среднего отклонения данных разметки колосьев пшеницы в обучающей выборке, а для алгоритма оптимизации использован алгоритм Адам.

Результаты научных исследований показали, что точность детекции на обучающей выборке с учётом аугментации по метрике F1-score с пороговым значением 0,6 (совпаде-




Рис. 1. Размеченные изображения колосьев

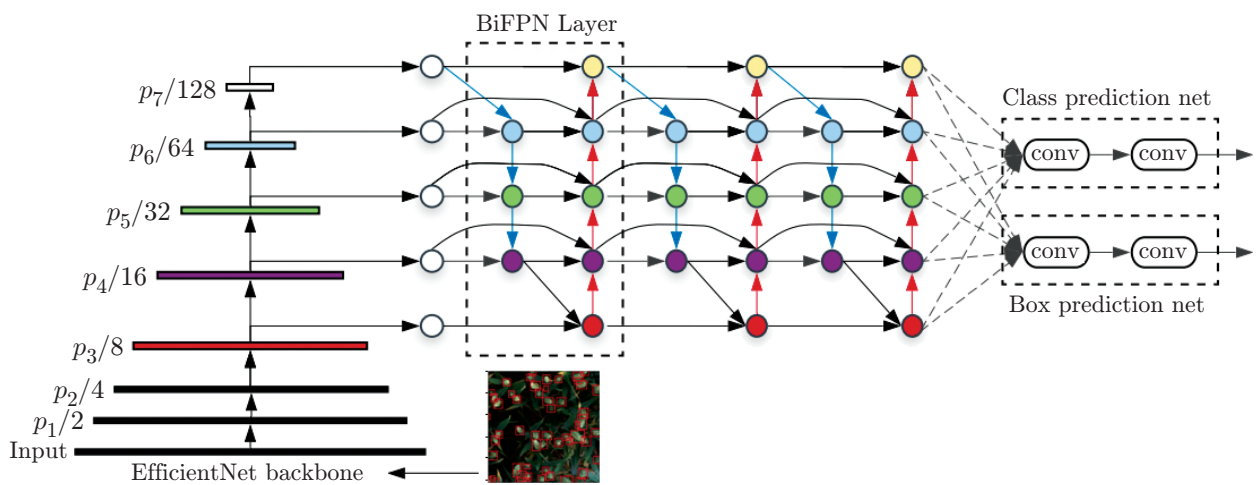


Рис. 2. Архитектура EfficientDet [26]




Рис. 3. Распределение количества колосьев на изображениях

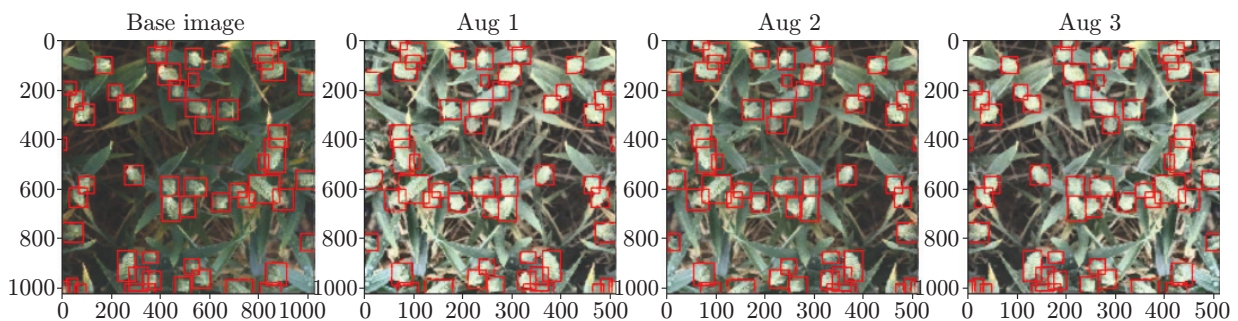


Рис. 4. Аугментация изображений

ние площади предсказанной разметки и фактической) оказалась равной 0,88012. Точность детекции на обучающей выборке без учёта аугментации по метрике F1-score с пороговым значением 0,6 (совпадение площади предсказанной разметки и фактической) оказалась равной 0,79. Дальнейшие эксперименты связаны с разбивкой выборки на обучающую (80 %) и контрольную (20 %). Точность детекции с учётом аугментации на обучающей выборке по метрике F1-score с пороговым значением 0,6 составила 0,75, а на контрольной — 0,69. Точность детекции без учёта аугментации на обучающей выборке по метрике F1-score с пороговым значением 0,6 составила 0,64, а на контрольной — 0,58. Таким образом, точность обнаружения количества колосьев пшеницы значительно повышается, если учитывать аугментацию графических изображений.

Заключение. Оценка урожайности без применения средств автоматизации является трудоёмкой задачей с большой погрешностью. С использованием нейросетевого подхода осуществляется обнаружение колосьев пшеницы. Обучение происходит с применением SGD. Используя общедоступный набор данных из более 3400 изображений пшеницы, глубокая свёрточная нейронная сеть обучается определять наличие колосьев, достигая точности обнаружения более 0,88. В данной работе использованы методы глубокого обучения для автоматического обнаружения колосьев по изображениям фрагментов пшеничного поля. Учитывая широкое распространение смартфонов с возможностью выхода в интернет, наличие фотокамер, а также систем беспилотных летательных аппаратов, подобная система может повсюду применяться для прогнозирования урожайности зерновых культур по всему миру.

СПИСОК ЛИТЕРАТУРЫ

1. **Mwebaze E., Gebru T., Frome A. et al.** iCassava 2019 Fine-Grained Visual Categorization Challenge. URL: <https://arxiv.org/abs/1908.02900> (дата обращения: 20.03.2021).
2. **Scharr H., Dee H., French A. P. et al.** Special issue on computer vision and image analysis in plant phenotyping // *Machine Vis. and Appl.* 2016. **27**. P. 607–609.
3. **Rahman C. R., Arko P. S., Ali M. E. et al.** Identification and recognition of rice diseases and pests using convolutional neural networks // *Biosyst. Eng.* 2020. **194**. P. 112–120. DOI: 10.1016/j.biosystemseng.2020.03.020.
4. **An international computer science competition to count wheat ears more effectively, using image analysis.** AICrowd. 2021 Challenge. Global Wheat Dataset. URL: <http://www.global-wheat.com/2020-challenge/> (дата обращения: 20.03.2021).
5. **Global Wheat Detection.** Kaggle. URL: <https://www.kaggle.com/c/global-wheat-detection/data?select=train> (дата обращения: 20.03.2021).
6. **David E., Serouart M., Smith D. et al.** Global Wheat Head Dataset 2021: More diversity to improve the benchmarking of wheat head localization methods. 2021. URL: <https://arxiv.org/ftp/arxiv/papers/2105/2105.07660.pdf> (дата обращения: 20.03.2021).
7. **Reynolds M. P., Borlaug N. E.** Applying innovations and new technologies for international collaborative wheat improvement // *The Journ. Agricult. Sci.* 2006. **144**, Iss. 2. P. 95–110.
8. **Tan M., Le Q.** EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. URL: <https://arxiv.org/pdf/1905.11946.pdf> (дата обращения: 20.03.2021).
9. **Осипов А. Л., Трушина В. П.** Теория принятия решений в химико-биологических исследованиях // *В мире научных открытий.* 2015. **64**, № 2–4. С. 843–849.
10. **Tereshchenko S., Perov A., Osipov A.** Определение заболеваний маниока методами компьютерного зрения // *Siberian Journ. Life Sci. and Agricult.* 2021. **13**, № 1. С. 144–155. DOI: 10.12731/2658-6649-2021-13-1-144-155.
11. **Tereshchenko S., Perov A., Osipov A.** Классификация внекорневых заболеваний яблоневых культур методами компьютерного зрения // *Siberian Journ. Life Sci. and Agricult.* 2021. **13**, № 3. С. 103–118. DOI: 10.12731/2658-6649-2021-13-3-103-118.
12. **Brisson N., Gate Ph., Gouache D. et al.** Why are wheat fields stagnating in Europe? A comprehensive data analysis for France. *Field Crops Research.* Elsevier, 2010. **119**, N 1. P. 201–212.
13. **Osipov A. L., Bobrov L. K.** The use of statistical models of recognition in the virtual screening of chemical compounds // *Automatic Document. and Math. Linguistics.* 2012. **46**, N 4. P. 153–158. URL: <https://link.springer.com/article/10.3103/S0005105512040024> (дата обращения: 20.03.2021).
14. **Tete T. N., Kamlu S.** Plant Disease Detection Using Different Algorithm // *Proc. of the Second Int. Conference on Research in Intelligent and Computing in Engineering «Global Wheat Detection».* 2017. Vol. 10. P. 103–106. DOI: 10.15439/2017R24.
15. **Борзов С. М., Потатуркин О. И.** Выбор информативной системы признаков при классификации сельскохозяйственных культур по гиперспектральным данным // *Автометрия.* 2020. **56**, № 4. С. 134–144. DOI: 10.15372/AUT20200414.
16. **Терещенко С. Н., Перов А. А., Осипов А. Л.** Особенности применения предобученных сверточных нейронных сетей к задачам стегаанализа графических изображений // *Автометрия.* 2021. **57**, № 4. С. 98–105. DOI: 10.15372/AUT20210412.
17. **Терещенко С. Н., Осипов А. Л., Моисеева Е. Д.** Прогнозирование состава широкой фракции лёгких углеводородов методами машинного обучения при трубопроводной транспортировке // *Автометрия.* 2022. **58**, № 1. С. 104–110. DOI: 10.15372/AUT20220100.

18. **Khaki S., Safaei N., Pham H., Wang L.** Wheatnet: A lightweight convolutional neural network for high-throughput image-based wheat head detection and counting. 2021. URL: <https://arxiv.org/pdf/2103.09408.pdf> (дата обращения: 20.03.2021).
19. **Phadikar S., Sil J.** Rice Disease Identification Using Pattern Recognition Techniques // Proc. of the 11th Int. Conference on Computer and Information Technology. Khulna, Bangladesh, 24–27 Dec., 2008. DOI: 10.1109/ICCITECHN.2008.4803079.
20. **Lee D., Back C., Win N. K. K.** Biological characterization of marssonina coronaria associated with apple blotch disease // Mycobiology. 2011. **39**, N 3. P. 200–205. DOI: 10.5941/MYCO.2011.39.3.200.
21. **Liu B., Zhang Y., He D., Li Y.** Identification of apple leaf diseases based on deep convolutional neural networks // Symmetry. 2017. **10**, N 1. P. 1–16. DOI: 10.3390/sym10010011.
22. **Hasan M., Chopin J. P., Laga H., Miklavcic S. J.** Detection and analysis of wheat spikes using convolutional neural networks // Plant Methods. 2018. **14**. DOI:10.1186/s13007-018-0366-8.
23. **Revathi P., Hemalatha M.** Classification of cotton leaf spot diseases using image processing edge detection techniques // Proc. of the Int. Conference on Emerging Trends in Science, Engineering and Technology (INCOSSET). Tiruchirappalli, India, 13–14 Dec. 2012. DOI: 10.1109/INCOSSET.2012.6513900.
24. **Reyes A. K., Caicedo C., Camargo J. E.** Fine-tuning deep convolutional networks for plant recognition // Proc. of the Conference and Labs of the Evaluation Forum (CLEF 2015). Toulouse, France, Sept. 8–11, 2015. Corpus ID: 12895326. 9 p.
25. **Khirade S. D., Patil A. B.** Plant disease detection using image processing // Proc. of the Int. Conference on Computing Communication Control and Automation. Pune, India, 26–27 Feb., 2015. DOI: 10.1109/ICCUBE.2015.153.
26. **Филлюшкина Ю.** Новая архитектура нейросети — EfficientDet. Хабр. 25.05.2020. URL: <https://habr.com/ru/post/503766/> (дата обращения: 20.03.2021).

Поступила в редакцию 30.03.2022

После доработки 28.04.2022

Принята к публикации 18.05.2022
