



<https://doi.org/10.26898/0370-8799-2024-12-1>

УДК: 633.12:632.51:632.911.4

Тип статьи: оригинальная

Type of article: original

Использование методов глубокого обучения для обнаружения и классификации сорняков в посевах *Fagopyrum esculentum*

✉ Риксен В.С., Шпак В.А.

Сибирский федеральный научный центр агробиотехнологий Российской академии наук
Новосибирская область, р.п. Краснообск, Россия

✉ e-mail: Riclog@mail.ru

В последние годы активно развивается технология картирования сорняков при помощи беспилотных летательных аппаратов. Определение местоположения сорной растительности дает возможность создавать карты заданий для гербицидных обработок. Это способствует сокращению объема применяемых гербицидов и снижению экологической нагрузки. Однако для выбора оптимальной стратегии борьбы необходимо идентифицировать видовой состав, количественное обилие и фазы роста сорняков на конкретном поле. Развитие методов глубокого обучения на базе сверточных нейронных сетей помогает в решении данной задачи. В частности, обученный алгоритм способен автоматически извлекать информацию из изображений, обнаруживать и классифицировать сорняки. В статье рассмотрено построение классификаторов изображений с использованием архитектуры ResNet-18, ResNet-34 и ResNet-50. В качестве исходной информации использованы результаты фитосанитарного мониторинга посевов гречихи (*Fagopyrum esculentum* Moench) и фотографии учетных площадок. В посевах преобладали следующие сорняки: овсюг обыкновенный (*Avena fatua* L.), просо куриное (*Echinochloa crus-galli* (L.) Beauv.) и вьюнок полевой (*Convolvulus arvensis* L.). Согласно количественной оценке сорняков на исследуемых площадках каждому виду был присвоен идентификатор: 0 – для засоренности, превышающей экономический порог вредоносности, 1 – для засоренности, не превышающей данный показатель. Задачи классификатора – распознать сорняки на фотографии и определить одну из двух градаций засоренности участка (низкая либо высокая). Эффективность предлагаемого подхода подтверждена достаточно высоким качеством предсказаний классификаторов (доля верных классификаций для исходного набора из 24 изображений составляет от 83 до 88%) и построением матрицы ошибок.

Ключевые слова: сорные растения, глубокое обучение, классификатор, ResNet-18, ResNet-34, ResNet-50, гречиха

Using deep learning techniques to detect and classify weeds in *Fagopyrum esculentum* crops

✉ Riksen V.S., Shpak V.A.

Siberian Federal Research Centre of Agro-BioTechnologies of the Russian Academy of Sciences
Krasnoobsk, Novosibirsk region, Russia

✉ e-mail: Riclog@mail.ru

In recent years, the technology of weed mapping using unmanned aerial vehicles has been actively developing. Determining the location of weeds makes it possible to create task maps for herbicide treatments. This helps to reduce the amount of herbicides used and reduce the environmental load. However, to select the optimal control strategy, it is necessary to identify the species composition, quantitative abundance and growth phases of weeds in a particular field. The development of deep learning methods based on convolutional neural networks helps in solving this problem. In particular, the trained algorithm is able to automatically extract information from images, detect and classify

weeds. The article discusses the construction of image classifiers using the ResNet-18, ResNet-34 and ResNet-50 architecture. The results of phytosanitary monitoring of buckwheat (*Fagopyrum esculentum* Moench) crops and photographs of survey sites are used as initial information. The crops were dominated by annual monocotyledonous weeds – wild oat (*Avena fatua* L.), barnyard grass (*Echinochloa crus-galli* (L.) Beauv.) and field bindweed (*Convolvulus arvensis* L.). According to the quantitative assessment of the weeds in the study sites, each species was assigned an identifier of 0 – for those exceeding the economic threshold of harmfulness and 1 – for those not exceeding it. The task of the classifier is to recognize these weeds in the photograph and determine one of two gradations of weediness of the site (low or high). The efficiency of the proposed approach is confirmed by a sufficiently high quality of the classifier predictions (the number of correct classifications for the original set of 24 images varies from 83 to 88%) and the construction of a Confusion matrix.

Keywords: weeds, deep learning, classifier, ResNet-18, ResNet-34, ResNet-50, buckwheat

Для цитирования: Риксен В.С., Шпак В.А. Использование методов глубокого обучения для обнаружения и классификации сорняков в посевах *Fagopyrum esculentum* // Сибирский вестник сельскохозяйственной науки. 2024. Т. 54. № 12. С. 5–14. <https://doi.org/10.26898/0370-8799-2024-12-1>

For citation: Riksen V.S., Shpak V.A. Using deep learning techniques to detect and classify weeds in *Fagopyrum esculentum* crops. *Sibirskii vestnik sel'skokhozyaistvennoi nauki* = *Siberian Herald of Agricultural Science*, 2024, vol. 54, no. 12, pp. 5–14. <https://doi.org/10.26898/0370-8799-2024-12-1>

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest

The authors declare no conflict of interest.

ВВЕДЕНИЕ

Прогнозируемый рост численности мирового населения к 2050 г. может привести к увеличению спроса на продовольствие на 70%. В связи с этим одной из важнейших задач для исследовательского сообщества в сфере АПК является внедрение интеллектуальных систем с целью повышения урожайности сельскохозяйственных культур¹ [1–3].

Имеющая большое продовольственное значение гречиха по уровню урожайности уступает всем зерновым культурам. Средний показатель урожайности гречихи в России составляет 0,44 т/га. Тем не менее в оптимальных условиях она способна обеспечить урожайность 2,5–3,0 т/га и более² [4].

Одним из главных факторов, ограничивающих урожайность культур, являются сорные растения. Они создают напряженные конкурентные отношения в борьбе за свет, влагу, питательные вещества и не дают куль-

турным растениям реализовать свои потенциальные возможности [5].

Защита растений является неотъемлемым звеном в ограничении действий негативных факторов на формирование продуктивности сельскохозяйственных культур. Против сорных растений используется комплекс агротехнических и химических средств. Первый включает в себя систему основной, до- и послепосевной обработки, соблюдение севооборотов, обеспечение оптимальных сроков, глубины посева, норм высева и густоты стеблестоя. Второй предполагает использование гербицидов, когда агротехнические средства оказались недостаточными и засоренность посевов превышает экономический порог вредоносности (ЭПВ). Применение гербицидов позволяет ликвидировать сорняки, повысить показатели урожайности, упростить уход за сельскохозяйственными культурами. Для эффективной разработки мероприятий

¹Holzworth D.P., Huth N.I., de Voil P.G. et al. APSIM – evolution towards a new generation of agricultural systems simulation // Environmental modeling & software. 2014. Vol. 62. P. 327–350.

²Farooq S., Rehman R.U., Pirzadah T.B., Malik B., Dar F.A., Tahir I. Cultivation, agronomic practices, and growth performance of buckwheat // Molecular breeding and nutritional aspects of buckwheat. Oxford: Academic Press, 2016. P. 299–319.

по борьбе с сорняками необходимо располагать подробной информацией о составе сорного компонента на полях [6]. Это требует большого количества человеческого ресурса, поэтому возникает необходимость разработки различных автоматизированных подходов к мониторингу сорняков. К тому же автоматизация процесса связана с сокращением объема применяемых гербицидов, что снизит экологическую нагрузку на территории [7].

Интеграция методов искусственного интеллекта в область сельского хозяйства играет важную роль в повышении эффективности производства^{3,4} [8, 9]. Методы глубокого обучения, применяемые к цифровым фотографиям, могут помочь идентифицировать сорняки путем машинной обработки изображений⁵ [10]. Для классификации изображений существует достаточно много архитектур: например, AlexNet [11], GoogLeNet⁶, ResNet⁷ и др.

Цель исследования – разработать модель на базе архитектуры ResNet для семантической сегментации фотоснимков пашни, занятой гречихой, для идентификации сорняков и классификации степени интенсивности их присутствия.

МАТЕРИАЛ И МЕТОДЫ

Для разработки моделей на базе архитектуры ResNet были использованы фотографии с разрешением 1440 × 1920, полученные при помощи мобильной фотокамеры, а также результаты учета засоренности посевов гречихи на 24 площадках.

Мониторинг сорняков проводили в фазу развития первых настоящих листьев гречихи посевной (*Fagopyrum esculentum* Moench)

на четырех полях с использованием количественной методики учета сорняков на площади 0,25 м². Количество площадок учета зависело от размера поля.

На исследуемых участках с разной интенсивностью присутствовали такие сорные растения, как овсюг обыкновенный (*Avena fatua* L.), выюнок полевой (*Convolvulus arvensis* L.) и просо куриное (*Echinochloa crus-galli* (L.) Beauv.). Задача классификатора состояла в распознавании сорняков на фотографии и определении одной из двух градаций засоренности ими участка – низкая или высокая. На полях с гречихой было определено шесть классов засоренности: Avenafatua0, Avenafatua1, Convolvulusarvensis0, Convolvulusarvensis1, Echinochloacruss-galli0, Echinochloacruss-galli1. Идентификатор с 0 присваивался классу с засоренностью, не превышающей ЭПВ, 1 – с засоренностью, превышающей ЭПВ⁸.

На одной фотографии может присутствовать как один сорняк с соответствующей градацией, так и несколько. Таким образом, задача построения искомых классификаторов относится к задаче многокомпонентной классификации изображений по нескольким меткам.

Для выявления сорняков и определения их интенсивности была использована архитектура ResNet. Одним из преимуществ применения нейросетей вида ResNet является наличие готового фреймворка PyTorch. Для PyTorch построена удобная оболочка FastAi, позволяющая легко оперировать компонентами этого фреймворка [12]. Построение представленных в настоящей работе нейронных сетей ResNet-18, ResNet-34 и ResNet-50 ос-

³Potena C., Nardi D., Pretto A. Fast and accurate crop and weed identification with summarized train sets for precision agriculture // Intelligent autonomous systems: Proceedings of the 14th International conference IAS-2016. Cham: Springer, 2017. P. 105–121.

⁴Zhang W., Hansen M.F., Volonakis T.N., Smith M., Smith L., Wilson J., Ralston G., Broadbent L., Wright G. Broad-leaf weed detection in pasture // IEEE-2018: 3rd International conference on image, vision and computing (ICIVC). Bristol, 2018. P. 101–105.

⁵Riksen V., Shpak V. Deep convolutional neural network model for weed identification in oil flax crops // International conference on agriculture digitalization and organic production. Singapore: Springer Nature Singapore, 2023. P. 305–314.

⁶Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. Going deeper with convolutions // Proceedings of the IEEE conference on computer vision and pattern recognition. Boston, 2015. P. 1–9.

⁷He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // Proceedings of the IEEE conference on computer vision and pattern recognition. Boston, 2016. P. 770–778.

⁸Кирюшин В.И., Власенко А.Н., Каличкин В.К., Власенко Н.Г., Фильмонов Ю.П., Тарасов А.С., Понько В.А., Южаков А.И., Синищев В.Е., Новиков В.М., Шоба В.Н., Усолкин В.Т., Солосич Н.А., Коняева Н.М., Полухин Н.И. Адаптивно-ландшафтные системы земледелия Новосибирской области: коллектив. монография. Новосибирск, 2000. 388 с.

новано на применении предобученных сверточных нейросетей (компоненты фреймворка PyTorch).

На рис. 1 в качестве примера приведена архитектура ResNet-18. В ней имеются четыре сверточных блока, обозначенных на рисунке розовым, фиолетовым, желтым и оранжевым цветами. Каждый блок содержит четыре сверточных слоя. Вместе с первым сверточным слоем и последним полносвязным слоем получается 18 слоев. Последний слой обозначен как avg pool. Выход этого слоя сглаживается и подается на слой с функцией активации softmax, обозначенный как fc и выполняющий роль финального классификатора выходных классов. На схеме fc указан с максимально возможным числом классов – 1000.

В блоках свертку на каждом слое производят фильтры размером 3×3 , обозначенные как conv, n , где n – число используемых фильтров. Если выходные карты признаков имеют одинаковый размер, то слои имеют равное число фильтров. Число фильтров удваивается в слоях (обозначено $/2$), когда выходная карта признаков уменьшена вдвое. Происходит понижение частоты дискретизации сверточных слоев с шагом 2.

В процессе обучения и тестирования параметры, веса и смещения выбираются таким образом, чтобы минимизировать ошибку обучения, представляющую собой меру разности между фактическими и полученными на выходе сети признаками классов. В ResNet в качестве такой меры используется бинарная перекрестная энтропия как функция потерь, а оптимизация параметров, весов

и смещений сети осуществляется методом стохастического градиентного спуска.

Настраивая разное количество слоев и остаточных блоков, получаем другие модели ResNet, например более глубокие 34-слойную (ResNet-34) и 50-слойную (ResNet-50).

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

В ходе работы с архитектурой ResNet была проведена предварительная обработка изображений, включающая аугментацию данных для увеличения объема обучающего набора и повышения устойчивости модели к различным условиям съемки. Для этого использован прием увеличения объема исходных данных с помощью процедуры `aug_transforms`, встроенной в PyTorch. Такой подход позволил улучшить обобщающую способность классификатора, что особенно важно при наличии фоновых шумов и различных условий освещения на полях.

Процесс генерации синтетических обучающих изображений показан на рис. 2.

Ожидаемый размер входных данных для нейронных сетей ResNet составляет 224×224 пикселя. В PyTorch имеются функции для обработки изображений произвольного размера. Снимки с разрешением 1440×1920 были сначала уменьшены до 512×512 с помощью `Resize`, а затем масштабированы до необходимого формата.

Размеры векторных признаков напрямую влияют на объем вычислений и время обработки. Так как исходные цветные изображения сделаны на стандартную цифровую камеру, они представлены на компьютере в трех каналах: красном, зеленом и синем.




Рис. 1. Архитектура ResNet-18

Fig. 1. ResNet-18 architecture




Рис. 2. Аугментация исходных изображений
Fig. 2. Augmentation of original images

Выводы по ResNet формируются в виде вектора размером 6, где каждая компонента представляет вероятность наличия конкретного класса. При наличии многоклассового классификатора одно изображение может принадлежать к нескольким классам или вообще не иметь класса. Класс предсказывается, если вероятность превышает 50%.

Для повышения объективности модели обучались на тестовом наборе изображений. Были определены следующие параметры:

количество эпох, размер батча и скорость обучения. Обучение проводилось с оптимизатором Adam и включало разные эпохи (см. табл. 1). Одна эпоха означает итерацию по всем используемым изображениям, которые последовательно вводятся для обучения партиями по восемь снимков.

Точность (*accuracy_multi*) выбранных моделей варьирует от 85,3 до 90,8% и описывает долю примеров, которые были правильно классифицированы. F1 – это сбалансирован-

Табл. 1. Результаты обучения нейросетей ResNet по эпохам
Table 1. Results of training ResNet neural networks by epochs

Epoch	train_loss	valid_loss	accuracy_multi	F1
<i>ResNet-18</i>				
1	0,873353	0,451141	0,608333	0,536978
10	0,345972	0,231682	0,825000	0,721962
20	0,264712	0,285602	0,835000	0,755000
30	0,254362	0,231534	0,853354	0,788480
<i>ResNet-34</i>				
1	0,927994	0,501786	0,550000	0,531134
10	0,459588	0,248096	0,841667	0,711592
20	0,315624	0,243803	0,841667	0,787608
30	0,271576	0,264802	0,858333	0,802342
<i>ResNet-50</i>				
1	0,895698	0,453522	0,625000	0,555098
10	0,427128	0,159956	0,908333	0,864082
20	0,309589	0,151854	0,900000	0,816258
30	0,219612	0,148773	0,908333	0,829293

ная мера, которая фиксирует компромиссы, связанные с точностью и полнотой (их среднее геометрическое) и варьирует на финише в пределах 0,79–0,83. Напомним, что в классификации точность характеризуется как способность классификатора не маркировать отрицательный образец как положительный, а полнота представляет собой способность классификатора находить все положительные образцы.

Для полноты картины непосредственно оценим характеристики прогностических способностей нейросетей ResNet-18, ResNet-34 и ResNet-50 на исходной выборке

(см. табл. 2). Здесь 1 принимается за 100%-е совпадение, 0,5 – за 50%-е.

Далее приведена оценка прогностических качеств классификаторов на базе ResNet, которая получена на исходном наборе изображений (24 фотографии) (см. табл. 3).

Полученные оценки свидетельствуют о достаточно высоком качестве всех классификаторов и пригодности их применения для идентификации и классификации сорных растений в посевах гречихи. Предпочтительным является классификатор на основе ResNet-34, который дает примерно одинаковые результаты по сравнению с более слож-

Табл. 2. Сравнение соответствий между фактической засоренностью участка с гречихой и предсказаниями по классификаторам ResNet-18, ResNet-34, ResNet-50

Table 2. Comparison of correspondences between actual observations of weed infestation in a buckwheat plot and predictions by ResNet-18, ResNet-34 and ResNet-50 classifiers

Фактическая засоренность	Совпадение предсказанных и фактических классификаций		
	ResNet-18	ResNet-34	ResNet-50
Avenafatua1	1	1	1
Avenafatua1	1	1	1
Echinochloacrus-galli1	1	1	1
Convolvulusarvensis1 Echinochloacrus-galli1	1	1	1
Convolvulusarvensis1 Avenafatua1	0,5	0,5	0,5
Avenafatua1	1	1	1
Convolvulusarvensis0 Avenafatua1	1	0,5	1
Avenafatua1	1	1	1
Convolvulusarvensis1 Avenafatua1	1	1	1
Convolvulusarvensis0 Avenafatua1	0,5	1	0,5
Convolvulusarvensis0 Avenafatua1	1	1	1
Avenafatua1 Echinochloacrus-galli0	1	1	1
Convolvulusarvensis1 Avenafatua1	0,50	0,67	1
Convolvulusarvensis1	0,50	1	1
Convolvulusarvensis1	0,50	0,5	0
Convolvulusarvensis1	1	1	0
Avenafatua1	1	1	1
Convolvulusarvensis0 Avenafatua1	1	1	1
Convolvulusarvensis1	1	1	1
Convolvulusarvensis1	1	1	1
Convolvulusarvensis1	1	1	1
Convolvulusarvensis1	0,33	1	1
Convolvulusarvensis1 Avenafatua0	1	1	1
Convolvulusarvensis1	1	0	1

Табл. 3. Оценка качества классификаторов на базе ResNet-18, ResNet-34, ResNet-50
Table 3. Evaluation of the quality of classifiers based on ResNet-18, ResNet-34, ResNet-50

Классификатор	Общее число правильных классификаций	Правильные классификации, %	Абсолютно точные классификации, %
ResNet-18	19,8	83	67
ResNet-34	21,2	88	79
ResNet-50	21,0	88	83

ным классификатором ResNet-50 и превосходит по качеству оценок наиболее простой классификатор ResNet-18.

На рис. 3 представлен алгоритм работы классификаторов. Верхняя надпись описывает образец с истинными метками засоренности, нижняя – прогнозные метки для этого образца согласно классификатору.

Также для оценки качества классификаторов использована матрица ошибок (Confusion matrix). На рис. 4 представлены результаты матриц для разных моделей ResNet для каждой метки классов засоренности: 0 – Avenafatua0, 1 – Avenafatua1, 2 – Convolvulusarvensis0, 3 – Convolvulusarvensis1, 4 – Echinochloacrusgalli0, 5 – Echinochloacrusgalli1. С их помощью можно определить, с каким классом предсказания возникли проблемы.

Строки каждой матрицы (размерности 2×2) представляют количество изображений с истинными метками: Y соответствует числу изображений с выбранной меткой класса засоренности (образцы с истинной меткой данного класса), N – числу изображений всех остальных классов засоренности (все другие образцы с их истинными метками).

Столбцы представляют изображения, которые модель определила, как класс с выбранной меткой (столбец Y) и все остальные классы (столбец N).

Диагональ матрицы слева направо показывает изображения, которые были классифицированы верно (правильные прогнозы). Вне диагонали отражается неверная классификация (неправильные прогнозы).

Классы 1, 4 и 5 предсказываются более точно, с общим количеством правильных классификаций 23. Наименьшее количество правильных классификаций предсказано для класса 0.



Рис. 3. Результат классификации снимков с помощью нейросети ResNet
Fig. 3. The result of classification of the images by the neural network ResNet




Рис. 4. Матрица ошибок для классификаций ResNet-18 (а), ResNet-34 (б) и ResNet-50 (в)

Fig. 4. Confusion matrix for ResNet-18 (a), ResNet-34 (b) and ResNet-50 (v) classifications

Для модели ResNet-34 сложилась иная ситуация. Класс 0 был определен верно для всех 24 изображений. Классы 1, 2, 5 также предсказаны с высокой точностью. Наихудший результат прогноза для класса 3.

Для модели ResNet-50 абсолютно точно были предсказаны классы 0, 2, 4 и 5. Это свидетельствует о том, что данный классификатор показал самую высокую точность предсказаний.

Результаты тестирования подтвердили высокую эффективность классификаторов, что открывает новые возможности для автоматизации мониторинга засоренности посевов. Мы планируем дальнейшие исследования, нацеленные на улучшение алгоритмов и расширение набора данных для еще более точного распознавания и анализа сорняков.

ЗАКЛЮЧЕНИЕ

В ходе проведенного исследования были разработаны классификаторы на основе архитектуры ResNet, способные с высокой точностью определять сорняки и уровень засоренности ими по фотографиям полей гречихи. Наилучшие результаты демонстрирует классификатор на базе ResNet-34, показывающий аналогичную эффективность относительно более сложной модели ResNet-50 и превосходящий простейший классификатор ResNet-18 по качеству оценок.

Разработанный метод отличается высокой степенью гибкости, так как модель может быть обучена на новом наборе данных, что позволяет ей становиться более универсальной и точной. Представленный в статье подход станет важным шагом к точному земледелию, помогая решать сложную задачу идентификации сорных растений в посевах сельскохозяйственных культур.

СПИСОК ЛИТЕРАТУРЫ

1. Jones J.W., Antle J., Basso B., Boote K.J., Conant R.T., Foster I., Herrero M., Janssen S., Porter C.H., Wheeler T.R. Brief history of agricultural systems modeling // *Agricultural systems*. 2017. Vol. 155 (3). P. 240–254.
2. Walter A., Finger R., Huber R., Buchmann N. Smart farming is key to developing sustainable agriculture // *Proceedings of the National Academy of Sciences*. 2017. Vol. 114. N 24. P. 6148–6150.
3. Caldera U., Breyer C. Assessing the potential for renewable energy powered desalination for the global irrigation sector // *Science of the total environment*. 2019. Vol. 694. P. 133598.
4. Дубенок Н.Н., Заяц О.А., Стрижакова Е.А. Формирование продукционного потенциала гречихи (*Fagopyrum esculentum* L.) в зависимости от уровня минерального питания и способа посева // *Известия Тимирязевской сельскохозяйственной академии*. 2017. № 6. С. 29–41. DOI: 10.26897/0021-342X-2017-6-29-41.
5. Ahmad A., Saraswat D., Aggarwal V., Etienne A., Hancock B. Performance of deep learning models for classifying and detecting common weeds in corn and soybean production systems // *Computers and electronics in agricul-*

ture. 2021. Vol. 184. P. 106081. DOI: 10.1016/j.compag.2021.106081.

6. Hasan A.M., Soheli F., Diepeveen D., Laga H., Jones M.G. A survey of deep learning techniques for weed detection from images // *Computers and electronics in agriculture*. 2021. Vol. 184. P. 106067. DOI: 10.1016/j.compag.2021.106067.
7. Lottes P., Behley J., Chebrolu N., Milioto A., Stachniss C. Robust joint stem detection and crop-weed classification using image sequences for plant-specific treatment in precision farming // *Journal of field robotics*. 2020. Vol. 37. N 1. P. 20–34. DOI: 10.1002/rob.21901.
8. Dian Bah M., Hafiane A., Canals R. Deep Learning with unsupervised data labeling for weeds detection on UAV images // *arXiv*. 2018. N 1805. P. 12395.
9. Priya S.J., Sundar G.N., Narmadha D., Ebenezer S. Identification of weeds using HSV color spaces and labelling with machine learning algorithms // *International journal of recent technology and engineering*. 2019. Vol. 8. N 1. P. 1781–1786.
10. Riksen V., Shpak V. Convolutional neural network for identification and classification of weeds in buckwheat crops // *Machine intelligence for smart applications: opportunities and risks*. Cham: Springer Nature Switzerland, 2023. P. 61–72. DOI: 10.1007/978-3-031-37454-8_3.
11. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks // *Communications of the ACM*. 2017. Vol. 60. N 6. P. 84–90. DOI: 10.1145/3065386.
12. Ховард Дж., Гуггер С. Глубокое обучение с fastai и PyTorch: минимум формул, минимум кода, максимум эффективности. СПб.: Питер, 2022. 624 с.

REFERENCES

1. Jones J.W., Antle J., Basso B., Boote K.J., Conant R.T., Foster I., Herrero M., Janssen S., Porter C.H., Wheeler T.R. Brief history of agricultural systems modeling. *Agricultural Systems*, 2017, vol. 155 (3), pp. 240–254.
2. Walter A., Finger R., Huber R., Buchmann N. Smart farming is key to developing sustainable agriculture. *Proceedings of the National Academy of Sciences*, 2017, vol. 114, no. 24, pp. 6148–6150.
3. Caldera U., Breyer C. Assessing the potential for renewable energy powered desalination for the

- global irrigation sector. *Science of the total environment*, 2019, vol. 694, p. 133598.
4. Dubenok N.N., Zayats O.A., Strizhakova E.A. Formation of buckwheat (*Fagopyrum esculentum* L.) productive capacity depending on the level of mineral fertilization and sowing method. *Izvestiya Timiryazevskoy sel'skokhozyaistvennoy akademii = Izvestiya of Timiryazev Agricultural Academy*, 2017, no. 6, pp. 29–41. (In Russian). DOI: 10.26897/0021-342X-2017-6-29-41.
 5. Ahmad A., Saraswat D., Aggarwal V., Etienne A., Hancock B. Performance of deep learning models for classifying and detecting common weeds in corn and soybean production systems. *Computers and electronics in agriculture*, 2021, vol. 184, p. 106081. DOI: 10.1016/j.compag.2021.106081.
 6. Hasan A.M., Soheli F., Diepeveen D., Laga H., Jones M.G. A survey of deep learning techniques for weed detection from images. *Computers and electronics in agriculture*, 2021, vol. 184, p. 106067. DOI: 10.1016/j.compag.2021.106067.
 7. Lottes P., Behley J., Chebrolu N., Milioto A., Stachniss C. Robust joint stem detection and crop-weed classification using image sequences for plant-specific treatment in precision farming. *Journal of field robotics*, 2020, vol. 37, no. 1, pp. 20–34. DOI: 10.1002/rob.21901.
 8. Dian Bah M., Hafiane A., Canals R. Deep Learning with unsupervised data labeling for weeds detection on UAV images. *arXiv*, 2018, no. 1805, p. 12395.
 9. Priya S.J., Sundar G.N., Narmadha D., Ebenezer S. Identification of weeds using HSV color spaces and labelling with machine learning algorithms. *International journal of recent technology and engineering*, 2019, vol. 8, no. 1, pp. 1781–1786.
 10. Riksen V., Shpak V. Convolutional neural network for identification and classification of weeds in buckwheat crops. *Machine intelligence for smart applications: opportunities and risks*. Cham: Springer Nature Switzerland, 2023, pp. 61–72. DOI: 10.1007/978-3-031-37454-8_3.
 11. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 2017, vol. 60, no. 6, pp. 84–90. DOI: 10.1145/3065386.
 12. Howard D., Gugger S. *Deep learning with fastai and PyTorch: minimum formulas, minimum code, maximum efficiency*. S.-Petersburg: Piter, 2022, 624 p. (In Russian).

ИНФОРМАЦИЯ ОБ АВТОРАХ

✉ **Риксен В.С.**, кандидат сельскохозяйственных наук, младший научный сотрудник; **адрес для переписки:** Россия, 630501, Новосибирская область, р.п. Краснообск, а/я 463; e-mail: Riclog@mail.ru

Шпак В.А., кандидат физико-математических наук, старший научный сотрудник

AUTHOR INFORMATION

✉ **Vera S. Riksen**, Candidate of Science in Agriculture, Junior Researcher; **address:** PO Box 463, Krasnoobsk, Novosibirsk Region, 630501, Russia; e-mail: Riclog@mail.ru

Vladimir A. Shpak, Candidate of Science in Physics and Mathematics, Senior Researcher

Дата поступления статьи / Received by the editors 17.09.2024
Дата принятия к публикации / Accepted for publication 29.10.2024
Дата публикации / Published 25.12.2024