

ГЛУБОКОЕ ОБУЧЕНИЕ ДЛЯ АВТОМАТИЗИРОВАННОГО МОНИТОРИНГА СОРНЯКОВ В ПОСЕВАХ ЗЕРНОВЫХ

В.С. Риксен, В.А. Шпак

Сибирский федеральный научный центр агробиотехнологий РАН, Краснообск, Россия

E-mail: riclog@mail.ru

Для цитирования: Риксен В.С., Шпак В.А. Глубокое обучение для автоматизированного мониторинга сорняков в посевах зерновых // Вестник НГАУ (Новосибирский государственный аграрный университет). – 2025. – № 3 (76). – С. 158–167. – DOI: 10.31677/2072-6724-2025-76-3-158-167.

Ключевые слова: точное земледелие, сверточные нейронные сети, ResNet, классификация сорняков, аугментация данных, многоклассовая классификация.

Реферат. Снижение урожайности сельскохозяйственных культур под воздействием биотических стрессоров, таких как сорные растения, остается актуальной проблемой агроэкосистем. Традиционные методы мониторинга засоренности, основанные на визуальной оценке, трудоемки и субъективны. В данной работе предложен подход автоматизированной идентификации сорняков в посевах яровой пшеницы и ячменя с использованием сверточных нейронных сетей (СНС) ResNet. Цель исследования — разработка классификаторов на базе архитектур ResNet-18, ResNet-34 и ResNet-50 для обнаружения 16 видов сорных растений и определения необходимости гербицидной обработки. Датасет включал 138 изображений разрешением 1340×1790 пикселей, полученных с мобильной камеры, и данные фитосанитарного мониторинга с 66 учетных площадок ($0,25 \text{ м}^2$). Для компенсации малого объема данных применена аугментация (библиотека `aug_transforms`, PyTorch) с операциями: случайные повороты, масштабирование, коррекция яркости и контрастности. Это позволило расширить выборку — не менее пяти изображений на класс. Изображения предобрабатывались: масштабирование до 512×512 пикселей с последующим сжатием до 224×224 для совместимости с ResNet. Обучение моделей проводилось в течение ста эпох с оптимизатором Adam (batch size = 16), метриками качества служили `accuracy_multi` (доля верных классификаций) и F1-score. Все модели достигли высокой точности (`accuracy_multi` > 95 %), однако F1-score варьировался от 0,60 до 0,74, что отражает сложности многоклассовой классификации. Наивысшие показатели F1 (0,74) продемонстрировала ResNet-18. Анализ матриц ошибок выявил проблемные классы: *Convolvulus arvensis* (6 ошибок), *Sinapis arvensis* (4 ошибки), что связано с недостаточной репрезентативностью данных. Классы 4, 7–10 и 14 распознавались с максимальной точностью. Также Confusion Matrix выявила неоднозначную эффективность глубоких архитектур ResNet.

DEEP LEARNING FOR AUTOMATED WEED MONITORING IN GRAIN CROPS

V.S. Riksen, V.A. Shpak

Siberian Federal Research Center for Agrobiotechnologies, Russian Academy of Sciences, Krasnoobsk, Russia

E-mail: riclog@mail.ru

Keywords: precision farming, convolutional neural networks, ResNet, weed classification, data augmentation, multi-class classification.

Abstract. Crop yield reduction under the influence of biotic stressors such as weeds remains a pressing issue in agroecosystems. Traditional methods of weed infestation monitoring based on visual assessment are labor-intensive and subjective. In this paper, an approach to automated weed identification in spring wheat and barley crops using ResNet convolutional neural networks (CNNs) is proposed. The objective of the study was to develop classifiers based on ResNet-18, ResNet-34, and ResNet-50 architectures to detect 16 weed species and determine the need for herbicide treatment. The dataset included 138 images with a resolution of 1340×1790 pixels obtained from a mobile camera and phytosanitary monitoring data from 66 survey plots (0.25 m^2). To compensate for the small amount of data, augmentation was used (`aug_transforms` library, PyTorch) with the following operations: random rotations, scaling, brightness and contrast correction. This allowed us to expand the sample by at least 5 images per class. The images were preprocessed: scaling to 512×512 pixels with subsequent compression to 224×224 for compatibility with ResNet. The models were trained for 100 epochs with the Adam optimizer (batch size = 16), the quality metrics were `accuracy_multi` (the proportion of correct classifications) and F1-score. All models

achieved high accuracy (accuracy_multi > 95%), but the F1-score ranged from 0.60 to 0.74, which reflects the complexity of multi-class classification. ResNet-18 demonstrated the highest F1 scores (0.74). Confusion matrix analysis revealed problematic classes: Convolvulus arvensis (6 errors), Sinapis arvensis (4 errors), which is due to insufficient data representativeness. Classes 4, 7–10, and 14 were recognized with the highest accuracy. Confusion Matrix also revealed ambiguous effectiveness of deep ResNet architectures.

Сельскохозяйственные культуры сталкиваются с различными стрессовыми факторами, влияющими на их урожайность. Эти стрессы делятся на два типа: абиотический (засуха, переувлажнение, экстремальные температуры) и биотический, который, помимо вредителей, включает конкуренцию с сорными растениями. Сорняки, активно поглощая ресурсы и затеняя культурные растения, становятся ключевым биотическим стрессором, снижающим эффективность агроэкосистем [1–3].

Традиционные методы борьбы с сорняками основаны на визуальном осмотре полей фермерами или агрономами, что требует значительных временных и трудовых затрат. Ручная идентификация видов сорных растений, их локализации и плотности распространения часто сопряжена с субъективностью оценок и необходимостью привлечения специалистов [4, 5]. Раннее обнаружение сорных растений критически важно для своевременного применения гербицидов или механической прополки, предотвращающих снижение урожайности и экономические потери [6, 7]. В этом контексте технологии точного земледелия, такие как беспилотные летательные аппараты (БПЛА), цифровые камеры и искусственный интеллект (ИИ), предлагают революционные решения для автоматизированного мониторинга сорняков. Эти инструменты позволяют оперативно сканировать большие площади, минимизируя ручной труд и сокращая время анализа [8–11].

Сверточные нейронные сети (СНС) стали ключевым инструментом в области компьютерного зрения благодаря своей способности автоматически выделять признаки из изображений и точно распознавать объекты. Одной из передовых архитектур СНС является ResNet (Residual Network) [12], которая использует инновационный подход с остаточными связями. Благодаря этому ResNet способна обучаться на архитектурах с десятками и сотнями слоев, сохраняя высокую точность даже в сложных задачах, таких как классификация изображений с высокой детализацией [13].

В сельском хозяйстве ResNet активно применяется для анализа данных, полученных с помощью цифровых камер, дронов и спутников. Цифровые камеры, установленные на полях или

сельскохозяйственной технике, обеспечивают непрерывный сбор данных в высоком разрешении, что критически важно для мониторинга состояния посевов. В сочетании с алгоритмами ResNet это позволяет автоматизировать процессы обнаружения сорняков, оценки густоты всходов и прогнозирования урожайности [14–18].

Исследования последних лет подтверждают, что ResNet демонстрирует исключительную эффективность в идентификации сорных растений. Например, архитектура успешно справляется с вариативностью условий съемки: изменениями освещенности, угла обзора, разрешения или наличия частичных препятствий (например, теней или капель воды на листьях) [19]. Это достигается за счет глубокого обучения, где сеть автоматически адаптируется к разнообразным сценариям, извлекая устойчивые признаки сорняков. Важным преимуществом ResNet является ее способность работать с большими массивами данных без потери производительности, что особенно актуально для сельского хозяйства, где анализ охватывает тысячи гектаров [20, 21].

Точность моделей ResNet в задачах классификации сорняков варьируется в диапазоне 83–94 % [22, 23]. Такой разрыв объясняется различиями в качестве исходных данных, настройкой гиперпараметров модели и условиями применения (например, тип культуры, стадия роста растений). Тем не менее даже минимальные значения точности превышают порог, необходимый для практического внедрения в системы автоматизированного мониторинга.

Цель данного исследования – разработка классификаторов на основе архитектур ResNet-18, ResNet-34 и ResNet-50 для идентификации сорняков на фоне зерновых культур и принятия решения о необходимости их гербицидной обработки.

ОБЪЕКТЫ И МЕТОДЫ ИССЛЕДОВАНИЙ

Для обучения СНС использовался датасет из 138 фотографий с разрешением 1340×1790 пикселей, полученных с помощью мобильной камеры, а также результаты фитосанитарного

мониторинга. Мониторинг сорняков проводился в фазу кушения пшеницы яровой и ячменя ярового на 66 учетных площадках (площадью 0,25 м²) с использованием количественной методики учета сорняков.

Разметка данных осуществлялась на уровне всего изображения. Экспертом-агрономом каждому снимку присваивался набор бинарных меток (1 – наличие вида на снимке, 0 – отсутствие) для

каждого из 16 целевых видов сорняков. Таким образом, задача была определена как многоклассовая многометочная классификация (multilabel classification), а не как детекция объектов. Такой подход был выбран в связи с конечной прикладной задачей – не точной локализацией каждого сорняка, а оценкой общего видового состава и принятием решения о необходимости обработки всего участка, соответствующего снимку (табл. 1).

Таблица 1

Выделенные виды сорняков
Selected weed species

Идентификатор	Метка	Идентификатор	Метка
Chenopodiumalbum	0	Panicumcapillare	8
Cirsiumarvense	1	Pastinacasylvestris	9
Convolvulusarvensis	2	Persicariahydropiper	10
Echinochloacrus-galli	3	Sinapisarvensis	11
Equisetumarvense	4	Sonchusarvensis	12
Euphorbiavirgata	5	Stachyssylvatica	13
Fallopiaconvolvulus	6	Taraxacumofficinale	14
Lappulasquarrosa	7	Viciasativa	15

В качестве основного инструмента выбраны сверточные нейросети ResNet (Residual Network) – архитектура, использующая остаточные блоки для улучшения обучения глубоких сетей. Ее преимущества включают высокую точность в задачах распознавания изображений и доступность предобученных моделей в рамках фреймворка PyTorch с упрощенным интерфейсом FastAi [12, 24]. В работе тестировались версии ResNet-18, ResNet-34 и ResNet-50.

Для компенсации ограниченного объема исходного набора данных была применена аугментация с использованием библиотеки aug_transforms в PyTorch. Набор преобразований включал случайные операции: вращение изображений, масштабирование, коррекцию яркости и контрастности. Это позволило расширить обучающую выборку для каждого класса сорняков – не менее пяти изображений. Перед обработкой

исходные изображения приводились к разрешению 512×512 пикселей, а затем уменьшались до 224×224 пикселей – стандартного формата для архитектуры ResNet.

Основу классификатора составляет поэтапная обработка изображения с использованием ResNet. Исходный снимок последовательно проходит через чередующиеся компоненты сети: сверточные слои, активационные функции и pool-слои (рис. 1). Результатом работы модели является многомерный вектор, где каждый элемент отражает вероятность присутствия на изображении соответствующего класса объекта. Порог обнаружения установлен на уровне 50 %. Если значение превышает этот показатель, объект считается распознанным. Поскольку классификатор поддерживает мультиобъектную детекцию, на одном изображении может быть идентифицировано несколько объектов либо ни одного.




Рис. 1. Общее описание методологии классификации сорняков
General description of the weed classification methodology

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЙ

Используемые нейросети обучались на основе тестовой выборки изображений (20 % обучающей выборки), которая применялась в рамках алгоритма обучения для повышения объективности и надежности моделей. Перед стартом тренировочного процесса были заданы ключевые параметры, включая количество эпох, размер

пакета (батча), скорость обучения и другие гиперпараметры.

Модели обучались в течение ста эпох с оптимизатором Adam и размером пакета (batch size) 16. В качестве метрик использовались: accuracy_multi – доля верно классифицированных изображений ($\geq 95\%$); F1-score — баланс между точностью (способность избегать ложных срабатываний) и полнотой (выявление всех целевых объектов), достигший значений 0,60–0,74 (табл. 2).

Таблица 2

Результаты обучения нейросетей ResNet'-ов по эпохам
Results of training ResNet neural networks by epochs

Epoch	train_loss	valid_loss	accuracy_multi	F1
1	2	3	4	5
ResNet-18				
1	1.069608	0.873279	0.171296	0.175209
30	0.558045	0.267663	0.680556	0.335875
60	0.157689	0.109132	0.953704	0.733093
100	0.075273	0.104148	0.958333	0.744048
ResNet-34				
1	1.128942	1.057829	0.210648	0.163933
30	0.558365	0.313367	0.615741	0.283189
60	0.135921	0.160684	0.946759	0.679255
100	0.057955	0.157266	0.953704	0.687047
ResNet-50				

1	2	3	4	5
1	1.090715	0.792652	0.185185	0.176185
30	0.516696	0.291023	0.645833	0.305252
60	0.114173	0.112951	0.958333	0.587990
100	0.045747	0.125068	0.962963	0.602195

Полученные оценки говорят о достаточно высоком качестве всех классификаторов и пригодности их применения в принятии решения о необходимости гербицидной обработки сорных растений.

На рис. 2 иллюстрируется алгоритм работы классификаторов. Верхняя надпись описывает об-

разец с истинными видами засоренности, надпись ниже – прогнозные метки засоренности для этого образца согласно классификатору. Идентификатор с меткой «1» обозначает участки с засоренностью сорняками выше ЭПВ и говорит о необходимости гербицидной обработки.

Convolvulusarvensis1;Persicariahydropiper1
Convolvulusarvensis1;Persicariahydropiper1



Cirsiumarvensel1;Convolvulusarvensis1
Convolvulusarvensis1



Convolvulusarvensis1;Euphorbiavirgata1;Sonchusarvensis1
Convolvulusarvensis1;Euphorbiavirgata1;Sonchusarvensis1



Convolvulusarvensis1;Stachyssylvatica1
Convolvulusarvensis1;Stachyssylvatica1



Рис. 2. Результат классификации четырех снимков
Classification result of four images

Для оценки качества построены матрицы ошибок (Confusion Matrix) по схеме «один против всех» (рис. 3–5). В строках матрицы (размерности 2×2) отображается распределение снимков по их фактическим меткам: Y – изображения, относящиеся к целевому классу засоренности (истинные позитивные случаи); N – совокупность снимков всех остальных классов (истинные негативные случаи). Столбцы матрицы соответствуют прогнозам модели: Y – снимки, классифицированные как целевой класс; N – снимки, отнесенные к другим категориям. Диагональ матрицы слева направо показывает изображения, которые были класси-

фицированы верно (правильные прогнозы), вне диагонали отражается неверная классификация (неправильные прогнозы). Такое представление позволяет локализовать проблемные зоны классификации и оценить, какие классы чаще всего путает модель.

Классы 1, 4, 7–10 и 13–15 были распознаны с высокой точностью, достигнув общего числа верных классификаций 138 (см. рис. 3). Наименьшая точность наблюдается для классов 2 (Convolvulusarvensis) и 11 (Sinapisarvensis), где было зафиксировано 6 и 4 ошибочных классификаций соответственно.




Рис. 3. Confusion matrix для классов засоренности для ResNet-18
Confusion matrix for contamination classes for ResNet-18

Матрица ошибок демонстрирует значительное ухудшение качества классификации при переходе к модели ResNet-34 (см. рис. 4). В сравнении с ResNet-18 количество абсолютно корректных предсказаний снизилось до одного случая (класс *Chenopodium album*), что опровер-

гает эффективность более глубокой архитектуры в обработке сложных признаков изображений. Классы *Convolvulus arvensis* и *Sonchus arvensis* стали источниками пяти ошибок. Это может быть связано с недостаточной репрезентативностью образцов в обучающей выборке.




Рис. 4. Confusion matrix для классов засоренности для ResNet-34
Confusion matrix for contamination classes for ResNet-34

Матрица ошибок выявила снижение эффективности модели ResNet-34 по сравнению с ResNet-18, что ставит под сомнение преимущество глубокой архитектуры для анализа сложных признаков.

Модель ResNet-50 показывает восемь примеров абсолютно точной классификации (см. рис. 5), что на семь результатов превышает показатели ResNet-34. При этом количество верных и ошибочных предсказаний 34-слойной сети оказалось сопоставимым с ResNet-18.




Рис. 5. Confusion matrix для классов засоренности для ResNet-50
Confusion matrix for contamination classes for ResNet-50

Несмотря на увеличение вычислительных ресурсов на 40 % для обучения и инференса, более сложная архитектура ResNet-50 демонстрирует лишь незначительное улучшение точности, что делает ее применение менее оправданным в сравнении с менее затратной ResNet-18.

ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Предложенный подход демонстрирует конкурентоспособные результаты в области автоматизации мониторинга сорняков. Полученная ассурасу_multi (>95 %) для всех тестируемых архитектур ResNet сопоставима с показателями аналогичных исследований, где точность обычно варьируется в диапазоне 83–97 % [19, 22]. Однако более низкие значения F1-score (0,60–0,74) по сравнению с F1 = 0,81 в работе de Camargo et al. (2021) подчеркивают специфические вызовы многоклассовой классификации при ограниченном объеме данных.

Выбор архитектур ResNet-18, ResNet-34 и ResNet-50 для данного исследования был обусловлен рядом факторов. Во-первых, архитекту-

ра ResNet является отраслевым стандартом для задач классификации изображений благодаря использованию остаточных блоков, решающих проблему затухания градиентов в глубоких сетях, и имеет широкую эмпирическую поддержку в сельскохозяйственных приложениях [12, 19, 22]. Во-вторых, эти конкретные модели представляют собой последовательность с увеличивающейся глубиной и сложностью (от 18 до 50 слоев), что позволяет экспериментально оценить влияние глубины сети на качество классификации при ограниченном объеме данных.

Результаты анализа показывают неоднозначную эффективность глубоких архитектур ResNet. Классы 4, 7–10 и 14 демонстрируют высокую точность (138 верных классификаций), однако классы 2 (*Convolvulus arvensis*), 1 (*Cirsium arvense*), 5 (*Euphorbia virgata*) и 11 (*Sinapis arvensis*) выделяются низкой точностью, вероятно, из-за недостаточной репрезентативности данных. Переход к ResNet-34 привел к резкому снижению качества: лишь один абсолютно верный прогноз (*Chenopodium album*) против результатов ResNet-18, что ставит под сомнение целесооб-

ность увеличения глубины сети. Несмотря на улучшение ResNet-50 (8 точных классификаций), ее производительность сопоставима с ResNet-18 при росте вычислительных затрат на 40 %, что делает ResNet-18 более оптимальным выбором для задач с ограниченными ресурсами. Основные ошибки связаны с классами, требующими расширения обучающей выборки.

Таким образом, работа подтверждает эффективность ResNet-18 в качестве компромиссного решения для автоматизированного мониторинга сорняков при ограниченных вычислительных ресурсах, но отмечает необходимость стратегий сбора данных для устойчивой работы в гетерогенных агросредах.

ВЫВОДЫ

1. Аугментация данных (aug_transforms, PyTorch) увеличила обучающую выборку в 6 раз за счет поворотов, масштабирования и коррекции яркости, сохранив семантику изображений. Это улучшило способность моделей к обобщению и компенсировало дефицит исходных данных.

2. Предобработка изображений (сжатие до 512×512 → масштабирование до 224×224,

RGB-каналы) обеспечила совместимость с ResNet, сохранив информативность и снизив вычислительные затраты.

3. Обучение моделей (100 эпох, batch size = 16, Adam) достигло высокой точности (accuracy_multi >95 %), но умеренные значения F1-меры (0,60–0,74) отразили сложности многоклассовой классификации из-за внутривидовой вариативности сорняков и артефактов съемки.

4. Классы 4, 7–10 и 14 показали высокую точность (138 верных классификаций), тогда как классы 2 (*Convolvulus arvensis*), 1 (*Cirsium arvense*), 5 (*Euphorbia virgata*) и 11 (*Sinapis arvensis*) стали проблемными (6–4 ошибок), вероятно, из-за недостаточной репрезентативности данных.

5. ResNet-34 продемонстрировал резкое снижение качества: один абсолютно верный прогноз (*Chenopodium album*) против девяти у ResNet-18, что ставит под сомнение эффективность глубоких архитектур.

6. ResNet-50 улучшила точность (восемь абсолютно верных классификаций), но ее производительность сопоставима с ResNet-18 при росте вычислительных затрат на 40 %, что делает ResNet-18 более практичным решением.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Compound heat and moisture extreme impacts on global crop yields under climate change* / C. Lesk, W. Anderson, A. Rigden [et al.] // *Nature Reviews Earth & Environment*. – 2022. – Vol. 3, No. 12. – P. 872–889. – DOI: 10.1038/s43017-022-00368-8.
2. *Plant adaptations to the combination of drought and high temperatures* / SI. Zandalinas, R. Mittler, D. Balfagón [et al.] // *Physiologia plantarum*. – 2018. – Vol. 162, No. 1. – P. 2–12. – DOI: 10.1111/ppl.12540.
3. *Chilling and drought stresses in crop plants: implications, cross talk, and potential management opportunities* / H.A. Hussain, S. Hussain, A. Khaliq [et al.] // *Frontiers in plant science*. – 2018. – Vol. 9. – P. 393. – DOI: 10.3389/fpls.2018.00393.
4. *Zimdahl R.L., Basinger N.T. Fundamentals of weed science* // Elsevier. – 2024. – P. 560.
5. *An ecological future for weed science to sustain crop production and the environment. A review* / C. MacLaren, J. Storkey, A. Menegat [et al.] // *Agronomy for Sustainable Development*. – 2020. – Vol. 40. – P. 1–29. – DOI: 10.1007/s13593-020-00631-6.
6. *Simard M.J., Laforest M. Early detection and management of herbicide-resistant weeds* // *Canadian Journal of Plant Science*. – 2024. – Vol. 104, No. 6. – P. 533–539. – DOI: 10.1139/cjps-2024-0021.
7. *Geddes C.M., Page E.R., Bae J. Forging new paths to manage herbicide-resistant weeds* // *Canadian Journal of Plant Science*. – 2024. – Vol. 105. – P. 1–5. – DOI: 10.1139/cjps-2024-0190.
8. *Kamilaris A., Prenafeta-Boldú F.X. Deep learning in agriculture: A survey* // *Computers and electronics in agriculture*. – 2018. – Vol. 147. – P. 70–90. – DOI: 10.1016/j.compag.2018.02.016.
9. *Early detection of broad-leaved and grass weeds in wide row crops using artificial neural networks and UAV imagery* / J. Torres-Sánchez, F.J. Mesas-Carrascosa, F.M. Jiménez-Brenes [et al.] // *Agronomy*. – 2021. – Vol. 11, No. 4. – P. 749. – DOI: 10.3390/agronomy11040749.
10. *Boosting precision crop protection towards agriculture 5.0 via machine learning and emerging technologies: A contextual review* / G.A. Mesías-Ruiz, M. Pérez-Ortiz, J. Dorado [et al.] // *Frontiers in Plant Science*. – 2023. – Vol. 14. – P. 1143326. – DOI: 10.3389/fpls.2023.1143326.

11. *Towards reducing chemical usage for weed control in agriculture using UAS imagery analysis and computer vision techniques* / R. Sapkota, J. Stenger, M. Ostlie, P. Flores // *Scientific reports*. – 2023. – Vol. 13, № 1. – P. 6548. – DOI: 10.1038/s41598-023-33042-0.
12. *Deep residual learning for image recognition* / K. He, X. Zhang, S. Ren, J. Sun // *Proceedings of the IEEE conference on computer vision and pattern recognition*. – 2016. – P. 770–778. – DOI: 10.1109/CVPR.2016.90.
13. *ShuffleNet: An extremely efficient convolutional neural network for mobile devices* / X. Zhang, X. Zhou, M. Lin, J. Sun // *Proceedings of the IEEE conference on computer vision and pattern recognition*. – 2018. – P. 6848–6856.
14. *Mulla D.J.* Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps // *Biosystems engineering*. – 2013. – Vol. 114, № 4. – P. 358–371. – DOI: 10.1016/j.biosystemseng.2012.08.009.
15. *Drones in agriculture: A review and bibliometric analysis, Computers and electronics in agriculture* / A. Rejeb, A. Abdollahi, K. Rejeb, H. Treiblmaier. – 2022. – Vol. 198. – P. 107017. – DOI: 10.1016/j.compag.2022.107017.
16. *MDFC-ResNet: An agricultural IoT system to accurately recognize crop diseases* / W.J. Hu, J. Fan, Y.X. Du [et al.] // *IEEE Access*. – 2020. – Vol. 8. – P. 115287–115298. – DOI: 10.1109/ACCESS.2020.3001237.
17. *Yağ İ., Altan A.* Artificial intelligence-based robust hybrid algorithm design and implementation for real-time detection of plant diseases in agricultural environments // *Biology*. – 2022. – Vol. 11, № 12. – P. 1732. – DOI: 10.3390/biology11121732.
18. *A review on UAV-based applications for plant disease detection and monitoring* / L. Kouadio, M. El Jarroudi, Z. Belabess [et al.] // *Remote Sensing*. – 2023. – Vol. 15, № 17. – P. 4273. – DOI: 10.3390/rs15174273.
19. *Weed identification in maize, sunflower, and potatoes with the aid of convolutional neural networks* / G.G. Peteinatos, P. Reichel, J. Karouta [et al.] // *Remote Sensing*. – 2020. – Vol. 12, № 24. – P. 4185. – DOI: 10.3390/rs12244185.
20. *Li D., Li Y., Zhang Z.* Analysis of convolutional neural networks-based approaches in fruit disease detection for smart agriculture applications // *Journal of Optics*. – 2024. – Vol. 53. – P. 4256–4265. – DOI: 10.1007/s12596-023-01592-1.
21. *Phenotyping alfalfa (Medicago sativa L.) root structure architecture via integrating confident machine learning with ResNet-18* / B.J. Weihs, Z. Tang, Z. Tian [et al.] // *Plant Phenomics*. – 2024. – Vol. 6. – P. 0251. – DOI: 10.34133/plantphenomics.0251.
22. *Optimized deep learning model as a basis for fast UAV mapping of weed species in winter wheat crops* / T. de Camargo, M. Schirrmann, N. Landwehr [et al.] // *Remote Sensing*. – 2021. – Vol. 13, № 9. – P. 1704. – DOI: 10.3390/rs13091704.
23. *Риксен В.С., Шнак В.А.* Использование методов глубокого обучения для обнаружения и классификации сорняков в посевах *Fagopyrum esculentum* // *Сибирский вестник сельскохозяйственной науки*. – 2024. – Т. 54, № 12 (313). – С. 5–14. – DOI: 10.26898/0370-8799-2024-12-1.
24. *Ховард Д., Гуггер С.* Глубокое обучение с fastai и PyTorch: минимум формул, минимум кода, максимум эффективности. – СПб., 2023. – 624 с.

REFERENCES

1. Lesk C., Anderson W., Rigden A., Coast O., Jägermeyr J., McDermid S., Davis K.F., Konar M., Compound heat and moisture extreme impacts on global crop yields under climate change, *Nature Reviews Earth & Environment*, 2022, Vol. 3, No. 12, pp. 872–889, DOI: 10.1038/s43017-022-00368-8.
2. Zandalinas S.I., Mittler R., Balfagón D., Arbona V., Gómez-Cadenas A., Plant adaptations to the combination of drought and high temperatures, *Physiologia plantarum*, 2018, Vol. 162, No. 1, pp. 2–12, DOI: 10.1111/ppl.12540.
3. Hussain H. A., Hussain S., Khaliq A., Ashraf U., Anjum S. A., Men S., Wang L., Chilling and drought stresses in crop plants: implications, cross talk, and potential management opportunities, *Frontiers in plant science*, 2018, Vol. 9, P. 393, DOI: 10.3389/fpls.2018.00393.
4. Zimdahl R.L., Basinger N.T., Fundamentals of weed science, *Elsevier*, 2024, P. 560.
5. MacLaren C., Storkey J., Menegat A., Metcalfe H., Dehnen-Schmutz K., An ecological future for weed science to sustain crop production and the environment. A review, *Agronomy for Sustainable Development*, 2020, Vol. 40, pp. 1–29, DOI: 10.1007/s13593-020-00631-6.
6. Simard M.J., Laforest M., Early detection and management of herbicide-resistant weeds, *Canadian Journal of Plant Science*, 2024, Vol. 104, No. 6, pp. 533–539, DOI: 10.1139/cjps-2024-0021.
7. Geddes C.M., Page E.R., Bae J., Forging new paths to manage herbicide-resistant weeds, *Canadian Journal of Plant Science*, 2024, Vol. 105, pp. 1–5, DOI: 10.1139/cjps-2024-0190.
8. Kamilaris A., Prenafeta-Boldú F.X., Deep learning in agriculture: A survey, *Computers and electronics in agriculture*, 2018, Vol. 147, pp. 70–90, DOI: 10.1016/j.compag.2018.02.016.
9. Torres-Sánchez J., Mesas-Carrascosa F.J., Jiménez-Brenes F.M., de Castro A.I., & López-Granados F., Early detection of broad-leaved and grass weeds in wide row crops using artificial neural networks and UAV imagery, *Agronomy*, 2021, Vol. 11, No. 4, P. 749, DOI: 10.3390/agronomy11040749.

10. Mesías-Ruiz G.A., Pérez-Ortiz M., Dorado J., De Castro A.I., Peña J.M., Boosting precision crop protection towards agriculture 5.0 via machine learning and emerging technologies: A contextual review, *Frontiers in Plant Science*, 2023, Vol. 14, P. 1143326, DOI: 10.3389/fpls.2023.1143326.
11. Sapkota R., Stenger J., Ostlie M., Flores P., Towards reducing chemical usage for weed control in agriculture using UAS imagery analysis and computer vision techniques, *Scientific reports*, 2023, Vol. 13, No. 1, P. 6548, DOI: 10.1038/s41598-023-33042-0.
12. He K., Zhang X., Ren S., Sun J., Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778, DOI: 10.1109/CVPR.2016.90
13. Zhang X., Zhou X., Lin M., Sun J., Shufflenet: An extremely efficient convolutional neural network for mobile devices, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 6848–6856.
14. Mulla D.J., Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps, *Biosystems engineering*, 2013, Vol. 114, No. 4, pp. 358–371, DOI: 10.1016/j.biosystemseng.2012.08.009.
15. Rejeb A., Abdollahi A., Rejeb K., Treiblmaier H., Drones in agriculture: A review and bibliometric analysis, *Computers and electronics in agriculture*, 2022, Vol. 198, P. 107017, DOI: 10.1016/j.compag.2022.107017.
16. Hu W.J., Fan J., Du Y.X., Li B.S., Xiong N., Bekkering E., MDfC-ResNet: An agricultural IoT system to accurately recognize crop diseases, *IEEE Access*, 2020, Vol. 8, pp. 115287–115298, DOI: 10.1109/ACCESS.2020.3001237.
17. Yağ İ., Altan A., Artificial intelligence-based robust hybrid algorithm design and implementation for real-time detection of plant diseases in agricultural environments, *Biology*, 2022, Vol. 11, No. 12, pp. 1732, DOI: 10.3390/biology11121732.
18. Kouadio L., El Jarroudi M., Belabess Z., Laasli S.-E., Roni M.Z.K., Amine I.D.I., Mokhtari N., Mokrini F., Junk J., Lahlali R., A review on UAV-based applications for plant disease detection and monitoring, *Remote Sensing*, 2023, Vol. 15, No. 17, pp. 4273, DOI: 10.3390/rs15174273.
19. Peteinatos G.G., Reichel P., Karouta J., Andújar D., Gerhards R., Weed identification in maize, sunflower, and potatoes with the aid of convolutional neural networks, *Remote Sensing*, 2020, Vol. 12, No. 24, pp. 4185, DOI: 10.3390/rs12244185.
20. Li D., Li Y., Zhang Z., Analysis of convolutional neural networks-based approaches in fruit disease detection for smart agriculture applications, *Journal of Optics*, 2024, Vol. 53, pp. 4256–4265, DOI: 10.1007/s12596-023-01592-1.
21. Weihs B.J., Tang Z., Tian Z., Heuschele D.J., Siddique A., Terrill T.H., Zhang Z., York L.M., Zhang Z., Xu Z., Phenotyping alfalfa (*Medicago sativa* L.) root structure architecture via integrating confident machine learning with ResNet-18, *Plant Phenomics*, 2024, Vol. 6, P. 0251, DOI: 10.34133/plantphenomics.0251.
22. de Camargo T., Schirrmann M., Landwehr N., Dammer K. H., Pflanz M., Optimized deep learning model as a basis for fast UAV mapping of weed species in winter wheat crops, *Remote Sensing*, 2021, Vol. 13, No. 9, pp. 1704, DOI: 10.3390/rs13091704.
23. Riksen V.S., SHpak V.A., *Sibirskij vestnik sel'skohozyajstvennoj nauki*, 2024, Vol. 54, No. 12 (313), pp. 5–14. (In Russ.)
24. Hovard D., Gugger S., *Glubokoe obuchenie s fastai i PyTorch: minimum formul, minimum koda, maksimum effektivnosti* (Deep Learning with Fastai and PyTorch: Minimum Formulas, Minimum Code, Maximum Efficiency), Sankt-Peterburg, 2023, 624 p. (In Russ.)

Информация об авторах:

В.С. Риксен, кандидат сельскохозяйственных наук, младший научный сотрудник

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

Contribution of the authors:

V.S. Riksen, PhD in Agricultural Sciences, Junior Researcher

V.A. Shpak, PhD in Physical and Mathematical Sciences, Senior Researcher

Вклад авторов:

Все авторы сделали эквивалентный вклад в подготовку публикации.

Авторы заявляют об отсутствии конфликта интересов.