

EDN: ZWFIHW

DOI: 10.22314/2073-7599-2025-19-4-21-28



Научная статья

УДК: 631.171:632.915:004.93



Сравнение подходов глубокого обучения к распознаванию заболевших растений картофеля

Алексей Викторович Сибирёв,
доктор технических наук,
главный научный сотрудник,
член-корреспондент Российской академии наук,
e-mail: sibirev2011@yandex.ru;
Алексей Юрьевич Овчинников,
младший научный сотрудник,
e-mail: aleksovchinn@gmail.com;

Владимир Сергеевич Тетерин,
кандидат технических наук,
старший научный сотрудник,
e-mail: v.s.teterin@mail.ru;
Николай Сергеевич Панферов,
кандидат технических наук,
старший научный сотрудник,
e-mail: nikolaj-panfyorov@yandex.ru;
Сергей Александрович Пехнов,
старший научный сотрудник,
e-mail: pehnov@mail.ru

Федеральный научный агроинженерный центр ВИМ, Москва, Российская Федерация

Исследования проводились в рамках гранта Российского научного фонда № 23-76-10062 «Разработка роботизированного комплекса с цифровой системой интеллектуального управления для ухода за растениями картофеля и исследованием закономерностей распространения инфекционных заболеваний в полевых условиях производства семян»

Реферат. Возможность своевременно отличать заболевшие сельскохозяйственные культуры от здоровых играет решающую роль в обеспечении продовольственной безопасности и минимизации экономических потерь. Машинное зрение в сочетании с алгоритмами глубокого обучения позволяет эффективно и точно отслеживать состояние посадок картофеля, выявляя симптомы заболеваний, что является более продуктивным подходом по сравнению с традиционными методами визуальной оценки. (*Цель исследования*) Сравнительный анализ одноэтапного и двухэтапного подходов к распознаванию заболевших и здоровых растений картофеля на основе алгоритмов глубокого обучения. (*Материалы и методы*) В исследовании использовали два подхода к процессу обучения нейронной сети с целью распознаванию заболевших и здоровых растений картофеля: одноэтапный и двухэтапный. В рамках одноэтапного подхода применялся один алгоритм глубокого обучения для одновременной классификации и локализации растений. Двухэтапный подход включал использование двух алгоритмов: первый определял границы растений, а второй классифицировал их как здоровые или заболевшие. С целью обучения алгоритмов использовались различные базы данных, включая снимки листьев и кустов картофеля. (*Результаты и обсуждение*) Проведен сравнительный анализ эффективности одноэтапного и двухэтапного подходов к распознаванию заболевших растений картофеля с использованием алгоритмов глубокого обучения. По каждому методу обучения было определено общее среднеквадратичное отклонение и среднеквадратичное отклонение для координат, построены матрицы запутанности. (*Выводы*) Двухэтапный подход продемонстрировал высокую эффективность в дифференциации больных и здоровых кустов картофеля, несмотря на небольшое снижение точности определения координат по сравнению с методом двухэтапного обучения, где использовались снимки как отдельных листьев, так и растений в целом. Данные методы имеют уникальные преимущества и могут быть интегрированы с современными технологиями для более эффективного выявления фитопатологий. **Ключевые слова:** определение заболеваний картофеля, машинное обучение, нейронные сети, машинное зрение, фитопрочистка, возделывание картофеля, определение координат растений.

■ **Для цитирования:** Сибирёв А.В., Овчинников А.Ю., Тетерин В.С., Панферов Н.С., Пехнов С.А. Сравнение подходов глубокого обучения к распознаванию заболевших растений картофеля // *Сельскохозяйственные машины и технологии*. 2025. Т. 19. N4. С. 21-28. DOI: 10.22314/2073-7599-2025-19-4-21-28. EDN: ZWFIHW.

Scientific article

Comparison of Deep Learning Approaches for Detecting Diseased Potato Plants

Alexey V. Sibirev,
Dr.Sc.(Eng.), chief researcher, corresponding member
of the Russian Academy of Sciences,
e-mail: sibirev2011@yandex.ru;

Alexey Yu. Ovchinnikov,
junior researcher,
e-mail: aleksovchinn@gmail.com;

Vladimir S. Teterin,

Ph.D.(Eng.), senior researcher,
e-mail: v.s.teterin@mail.ru;

Nikolay S. Panferov,

Ph.D.(Eng.), senior researcher;
e-mail: nikolaj-panfyorov@yandex.ru;

Sergey A. Pekhnov,

senior researcher,
e-mail: pehnov@mail.ru

Federal Scientific Agroengineering Center VIM, Moscow, Russian Federation

Abstract. The timely identification of diseased agricultural crops is essential for maintaining food security and reducing economic losses. The integration of machine vision with deep learning algorithms offers a more efficient and accurate method for monitoring potato crops and detecting disease symptoms than conventional visual assessment techniques. (*Research purpose*) This study aims to conduct a comparative analysis of one-stage and two-stage deep learning approaches for recognizing diseased and healthy potato plants. (*Materials and methods*) Two approaches were employed to train neural networks for the identification of diseased and healthy potato plants: a one-stage and a two-stage approach. In the one-stage approach, a single deep learning algorithm was used to simultaneously perform plant classification and localization. The two-stage approach utilized two separate algorithms: the first was responsible for detecting plant boundaries, while the second classified the identified regions as healthy or diseased. The models were trained on diverse datasets comprising images of individual potato leaves as well as entire plants. (*Results and discussion*) A comparative analysis was performed to evaluate the effectiveness of the one-stage and two-stage deep learning approaches in detecting diseased potato plants. For each training method, both the overall mean squared error and the coordinate-specific mean squared error were computed. Additionally, confusion matrices were generated to assess classification performance. The analysis revealed differences in accuracy and precision between the two approaches, highlighting their respective strengths and limitations. (*Conclusions*) The two-stage approach proved to be highly effective in distinguishing between diseased and healthy potato plants. Although it exhibited a slight reduction in coordinate-prediction accuracy – particularly when trained on both individual leaf images and whole-plant images – it offered superior classification performance. Both approaches demonstrate distinct advantages and hold significant potential for integration with modern technologies aimed at enhancing the early detection of phytopathologies in agricultural crops.

Keywords: potato disease detection, machine learning, neural networks, machine vision, phytodiagnostics, potato cultivation, plant coordinate detection.

■ **For citation:** Sibirev A.V., Ovchinnikov A.Yu., Teterin V.S., Panferov N.S., Pekhnov S.A. Comparison of deep learning approaches for detecting diseased potato plants. *Agricultural Machinery and Technologies*. 2025. Vol. 19. N4. 21-28 (In Russian). DOI: 10.22314/2073-7599-2025-19-4-21-28. EDN: ZWFIHW.

Своевременное выявление заболевших сельскохозяйственных растений особенно актуально в отношении картофеля — одной из важнейших продовольственных культур в России [1, 2]. Машинное зрение относится к ключевым технологиям в области искусственного интеллекта и является мощным инструментом распознавания и анализа изображения [3, 4].

В сельском хозяйстве применение машинного зрения для мониторинга состояния посадок, анализа урожайности и выявления вредителей позволяет оптимизировать агротехнические процессы и повысить урожайность [5-7]. В сочетании с алгоритмами глубокого обучения технологии машинного зрения трансформируют традиционные методы мониторинга посадок, обеспечивая точность и скорость [8, 9]. Анализ цветовых паттернов, текстурных особенностей и морфологических изменений растений методами машинного зрения позволяет выявлять симптомы различных заболеваний.

Развитие и внедрение машинного зрения способствуют повышению эффективности и точности

различных процессов, открывают новые возможности для научных исследований и практических приложений [10-12]. Особенно перспективны в этой области нейросетевые архитектуры, способные к автоматическому извлечению из изображений диагностически значимых признаков [7, 13, 14].

Разработка системы определения заболевших и здоровых растений картофеля с использованием глубокого обучения составляет важную задачу, как альтернатива трудоемким и менее эффективным традиционным методам при работе с большими объемами данных [15-17].

Цель исследования — провести сравнительный анализ одноэтапного и двухэтапного подходов к распознаванию заболевших и здоровых растений картофеля на основе алгоритмов глубокого обучения.

МАТЕРИАЛЫ И МЕТОДЫ. Методологический базис исследования предполагает дифференциацию двух принципиально разных подходов к решению поставленной задачи: одноэтапного и двухэтапного.

Одноэтапный подход (метод 1) к распознаванию заболевших и здоровых растений картофеля заклю-

чается в одновременной их классификации и локализации [18]. В этом случае используется один алгоритм глубокого обучения для выделения растений в рамки и присвоения ему соответствующей метки класса (заболевшее/здоровое).

При двухэтапном подходе используются два алгоритма глубокого обучения для разных целей. Первый алгоритм обучается только для выделения растений на изображении и определения их границы, а второй алгоритм обучается с целью классификации растений к группе заболевших или здоровых на основе анализа имеющихся признаков. Из-за особенностей типа данных, с которыми работает алгоритм, происходит повторное выделение объекта в рамки на втором этапе. В качестве алгоритмов глубокого обучения использовалась нейронная сеть YOLOv11 [19].

При реализации двухэтапного подхода использовались различные методы обучения с целью классификации растений. Первый из этих методов (метод 2.1) заключался в обучении с использованием базы данных, состоящей из снимков отдельных здоровых и заболевших листьев картофеля. Во втором методе (метод 2.2) использовалась база данных из снимков заболевших и здоровых кустов. Третий вариант (метод 2.3) предусматривал использование комбинированной базы данных из снимков здоровых и зараженных листьев и растений картофеля.

Результаты и обсуждение. Для сравнительного анализа эффективности применения одно- и двухэтапного подходов к распознаванию заболевших растений картофеля с помощью алгоритмов глубокого обучения была подготовлена тестовая выборка из 40 изображений кустов картофеля, на которых алгоритм не проходил обучение и валидацию.

На *рисунке 1* показана работа алгоритма глубокого обучения при использовании одноэтапного подхода, т.е. выделение области растения картофеля и классификация его как заболевшее или здоровое (в этом примере растение классифицировано как здоровое).



Рис. 1. Пример работы одноэтапного подхода к распознаванию заболевших и здоровых растений картофеля на основе алгоритма глубокого обучения (метод 1)

Fig. 1. Example of a one-step approach to detecting diseased and healthy potato plants using a deep learning algorithm (method 1)

Применение двухэтапного подхода к диагностике заболеваний картофеля, где второй алгоритм был обучен на основе анализа листьев растений (метод 2.1) представлен на *рисунке 2*. Основная идея состоит в возможности фокусировки на микроструктурных особенностях растения, в частности, листьев. Использование в процессе обучения базы данных из изображений отдельных здоровых и пораженных листьев обеспечило алгоритму возможность детального изучения различных паттернов повреждений и аномалий на уровне отдельных органов растения.



Рис. 2. Пример работы двухэтапного подхода к распознаванию заболевших и здоровых растений картофеля на основе алгоритма глубокого обучения (метод 2.1)

Fig. 2. Example of a two-step approach to detecting diseased and healthy potato plants using a deep learning algorithm (method 2.1)

При анализе полученных изображений можно заметить, что классификатор выделяет только часть куста как зараженное растение, в то время как область, используемая алгоритмом для определения координат всего растения, оказывается больше.

Использование двухэтапного подхода, в котором второй алгоритм был обучен с использованием изображений здоровых и зараженных кустов картофеля (метод 2.2), представлено на *рисунке 3*.




Рис. 3. Пример работы двухэтапного подхода к распознаванию заболевших и здоровых растений картофеля с обучением на втором этапе на кустах (метод 2.2)

Fig. 3. Example of a two-stage approach for detecting diseased and healthy potato plants, with the second stage learning on entire bushes (method 2.2)

Главная идея основана на восприятии состояния растения в целом, принимая во внимание взаимодействие между различными частями на снимках

заболевших и здоровых кустов. Это позволило алгоритму учитывать контекстуальные факторы и выявлять заболевания на системном уровне, охватывая весь организм растения.

Комбинированный подход при двухэтапном методе (второй алгоритм обучен на основе изображений здоровых и зараженных листьев и растений картофеля, метод 2.3) иллюстрирован на рисунке 4. Основная идея основана на создании возможности алгоритму учитывать как локальные признаки заболеваний листьев, так и особенности всего куста.



Рис. 4. Пример двухэтапного подхода к распознаванию заболевших и здоровых растений картофеля с обучением на втором этапе на отдельных листьях и кустах (метод 2.3)

Fig. 4. Example of a two-stage approach for detecting diseased and healthy potato plants, with the second stage learning on individual leaves and whole bushes (method 2.3)

Важно отметить, что если в рамках одной белой области (которая появляется вследствие работы первого этапа) выделяется несколько предсказаний, то выбирается область их перекрытия (если ее площадь больше 60%).

Для оценки корректности определения координат центра распознанных растений картофеля для каждого из подходов использовали среднее квадратическое отклонение (СКО) вычисленных координат центра объекта от эталонных координат (определенных человеком визуально) $X_{п}$, $Y_{п}$ и $X_{эт}$, $Y_{эт}$ – предсказанные и эталонные координаты центра растения картофеля на изображении, pix :

$$\begin{cases} \sigma_X = \sqrt{\frac{\sum_{i=1}^n (X_{п} - X_{эт})^2}{n}} \\ \sigma_Y = \sqrt{\frac{\sum_{i=1}^n (Y_{п} - Y_{эт})^2}{n}} \end{cases} \quad (1)$$

где σ_X , σ_Y – среднее квадратическое отклонение для координаты X и Y соответственно; $X_{п}$, $Y_{п}$ – предсказанные координаты центра растения картофеля на изображении, pix ; $X_{эт}$, $Y_{эт}$ – эталонные координаты центра растения картофеля на изображении, pix ; n – количество проанализированных изображений

Также оценивалось комбинированное среднее квадратическое отклонение на основе евклидова расстояния, т.е. метрика, объединяющая ошибки по обе-

им координатам (X и Y) в единый показатель точности определения положения точки:

$$\sigma_{общ} = \sqrt{\frac{\sum_{i=1}^n (\sqrt{(X_{п} - X_{эт})^2 + (Y_{п} - Y_{эт})^2})^2}{n}} \quad (2)$$

$\sigma_{общ}$ – общее среднее квадратическое отклонение.

С использованием полученных данных в программе *Excel* был построен график, характеризующий изменение среднее квадратического отклонения вычисленных координат от эталонных для каждого из предложенных подходов (рис. 5). Анализ этой зависимости показал, что двухэтапный подход к обучению с использованием базы данных, включающей изображения заболевших и здоровых растений картофеля (методы 2.2 и 2.3), дает лучший результат с точки зрения точности определения центра координат выделенного растения картофеля, так как СКО, т.е. ошибка, у этих методов оказалась наименьшей как по отдельным координатам, так и по комбинированному показателю.

Кроме точности определения координат, оценивалась корректность распределения растений к одному из классов (заболевшее или здоровое) с использованием такого общепринятого показателя, как матрица запутанности. Матрица запутанности представляет собой таблицу, по которой видно, насколько хорошо работает классификационная модель, определяющая принадлежность выделенного объекта к соответствующему классу, при сравнении ее предсказаний с истинными ответами [20].




Рис. 5. Среднее квадратическое отклонение вычисленных координат от эталонных для каждого метода

Fig. 5. Root mean square deviation of the calculated coordinates from the reference values for each method

Для каждого класса выявляется количество образцов, которые были правильно или неправильно классифицированы. Таким образом формируется комплексное представление о производительности модели с выделением как точных прогнозов, так и областей, где происходит неправильная классификация.

$$C = \begin{bmatrix} TN & FP \\ FN & TP \end{bmatrix}, \quad (3)$$

где TN – количество истинно отрицательных результатов для класса i , этот квадрант в матрице означает количество корректно классифицированных алгоритмом растений, принадлежащих к классу «0» (здоровое); FP – количество ложноположительных результатов для класса i , этот квадрат означает ошибку классификации, т.е. растения, принадлежащие к классу «0», были отнесены алгоритмом к классу «1» (заболевшее); FN – количество ложноотрицательных результатов для класса i , этот квадрант также означает ошибку классификации, когда растения, которые принадлежат к классу «1» (заболевшее) были отнесены алгоритмом к классу «0» (здоровое); TP – количество истинно положительных результатов для класса i , этот квадрант означает количество корректно классифицированных алгоритмом растений, принадлежащих к классу «1» (заболевшее).

Необходимо отметить, что на одном изображении может присутствовать больше одного куста картофеля, поэтому матрица запутанности содержит более 40 случаев классификации кустов картофеля.

Матрица запутанности для одноэтапного подхода к обучению представлена на [рисунке 6](#). Анализ ее показал, что были определены 67 растений картофеля, при этом 16 растений были ошибочно отнесены к заболевшим.

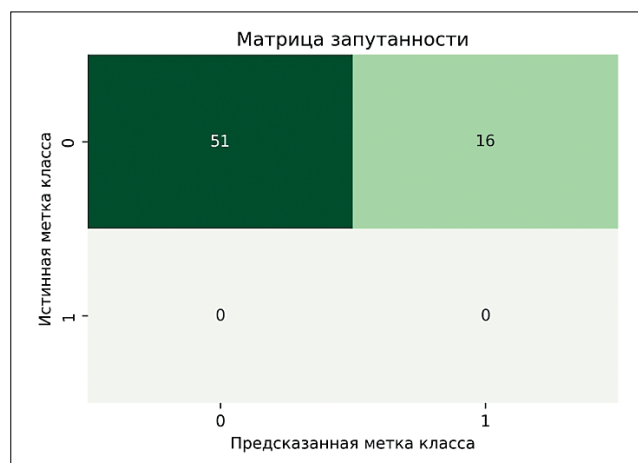


Рис. 6. Матрица запутанности одноэтапного подхода к распознаванию заболевших и здоровых растений картофеля (метод 1)

Fig. 6. Confusion matrix of the one-step approach for detecting diseased and healthy potato plants (method 1)

Матрица запутанности для двухэтапного подхода к диагностике заболеваний картофеля, где второй алгоритм был обучен на основе анализа листьев растений (метод 2.1), представлена на [рисунке 7](#).

Основная часть растений на тестовых изображениях, прошедших классификацию с использованием подхода к обучению на базе данных, содер-




Рис. 7. Матрица запутанности двухэтапного подхода к распознаванию заболевших и здоровых растений картофеля с обучением на втором этапе на отдельных листьях (метод 2.1)

Fig. 7. Confusion matrix of the two-stage approach for detecting diseased and healthy potato plants, with second-stage learning on individual leaves (method 2.1)

жащих только отдельные листья картофеля, была ошибочно распознана как заболевшие. Из 67 проанализированных растений 62 были классифицированы неверно, что указывает на ограниченность текущего подхода к обучению и его недостаточную обобщающую способность.

Матрица запутанности для двухэтапного подхода, в котором второй алгоритм был обучен с использованием изображений здоровых и зараженных кустов картофеля (метод 2.2), представлена на [рисунке 8](#).




Рис. 8. Матрица запутанности двухэтапного подхода к распознаванию заболевших и здоровых растений картофеля с обучением на втором этапе на кустах картофеля (метод 2.2)

Fig. 8. Confusion matrix of the two-stage approach for detecting diseased and healthy potato plants, with second-stage learning on potato bushes (method 2.2)




Рис. 9. Матрица запутанности двухэтапного подхода к распознаванию заболевших и здоровых растений картофеля с обучением на втором этапе на отдельных листьях картофеля и кустах (метод 2.3)

Fig. 9. Confusion matrix of the two-stage approach for detecting diseased and healthy potato plants, with second-stage learning on individual potato leaves and bushes (method 2.3)

Матрица запутанности для двухэтапного подхода, где второй алгоритм был обучен на основе изображений здоровых и зараженных листьев и растений картофеля (метод 2.3), представлен на рисунке 9.

Анализ матриц запутанности для методов 2.2 и 2.3 показал, что корректность распознавания значительно выше, чем при использовании в процессе обучения базы данных с изображением только отдельных зараженных и здоровых листьев картофеля, а также в сравнении с одноэтапным подходом с изображениями растений картофеля. Согласно полученным результатам в методе 2.2 было ошибочно распознано 8 растений, а в методе 2.3 – 10 растений.

Полученные результаты подтверждают, что использование более разнообразных данных на вто-

ром этапе обучения значительно повышает способность модели к точной классификации. Включение изображений здоровых и зараженных кустов, а также листьев позволяет модели лучше обобщать и различать здоровые и больные растения.

Таким образом, двухэтапный подход с использованием более репрезентативных данных на втором этапе обучения демонстрирует более высокую эффективность и надежность в классификации растений по сравнению с одноэтапным и двухэтапным подходами, использующими ограниченные данные.

Выводы. Исходя из полученных результатов, можно заключить, что двухэтапный подход, включающий обучение на втором этапе с использованием заболевших и здоровых растений картофеля (метод 2.2), демонстрирует высокую эффективность в решении задачи дифференциации больных и здоровых растений. Несмотря на незначительное снижение точности определения координат по сравнению с методом 2.3, метод 2.2 демонстрирует превосходство в классификации состояния растений.

Интеграция высокой точности локализации растений с высокой точностью классификации их состояния делает метод 2.2 наиболее перспективным для своевременного выявления заболеваний и предотвращения их распространения в сельскохозяйственной отрасли. При этом метод 2.3 также заслуживает внимания. Расширение обучающей выборки потенциально позволит обеспечить дальнейшее повышение точности классификации обоих методов.

Таким образом, можно отметить, что оба метода обладают уникальными преимуществами, а их интеграция с современными технологиями, включая дистанционное зондирование и генетические маркеры, открывает новые горизонты в области выявления фитопатологий, позволяя более эффективно управлять ресурсами и повышать урожайность сельскохозяйственных культур.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

- Борычев С.Н., Владимиров А.Ф., Колошеин Д.В. и др. К вопросу об исследованиях по хранению картофеля // *Вестник Рязанского государственного агротехнологического университета им. П.А. Костычева*. 2019. N2(42). С. 129-134. EDN: НУКQNU.
- Тарханова З.Э. Продовольственная безопасность государства: содержание, значение, угрозы, продовольственной безопасности // *Экономика и управление: проблемы, решения*. 2024. Т. 6. N10(151). С. 84-90. DOI: 10.36871/ek.ur.p.r.2024.10.06.010.
- Измайлов А.Ю., Лобачевский Я.П., Дорохов А.С. и др. Современные технологии и техника для сельского хозяйства – тенденции выставки AGRITECHNIKA 2019 // *Трактора и сельхозмашины*. 2020. N6. С. 28-40. DOI: 10.31992/0321-4443-2020-6-28-40.
- Дорохов А.С., Сибирев А.В., Пономарев А.Г., Сазонов Н.В. Аналитическое обоснование технологического процесса работы машины для удаления зараженных растений картофеля и овощных культур // *Аграрный научный журнал*. 2024. N5. С. 130-136. DOI: 10.28983/asj.y2024i5pp130-136.
- Лобачевский Я.П., Ценч Ю.С. Принципы формирования систем машин и технологий для комплексной механизации и автоматизации технологических процессов в растениеводстве // *Сельскохозяйственные машины и технологии*. 2022. Т. 16. N4. С. 4-12. DOI: 10.22314/2073-7599-2022-16-4-4-12.
- Алферьев Д.А. Практика реализации сверточных нейронных сетей в сельском хозяйстве и агропромышленном комплексе // *АгроЗооТехника*. 2020. Т. 3. N2.

- С. 4. DOI: 10.15838/alt.2020.3.2.4.
7. Аксенов А.Г., Тетерин В.С., Овчинников А.Ю. и др. Использование нейронной сети для выявления больных растений картофеля // *Аграрная наука*. 2022. N7-8. С. 167-171. DOI: 10.32634/0869-8155-2022-361-7-8-167-171.
 8. Ценч Ю.С., Годлевская Е.В. Математическое моделирование как инструмент проектирования сельскохозяйственных машин и агрегатов (применительно к истории развития научной школы Южного Урала) // *Сельскохозяйственные машины и технологии*. 2023. Т. 17. N2. С. 4-12. DOI: 10.22314/2073-7599-2023-17-2-4-12.
 9. Каличкин В.К. О необходимости трансформации парадигмы научных исследований по земледелию (сообщение второе) // *Сибирский вестник сельскохозяйственной науки*. 2024. Т. 54. N9(310). С. 102-115. DOI: 10.26898/0370-8799-2024-9-11.
 10. Arshaghi A., Ashourian M., Ghabeli L. Potato diseases detection and classification using deep learning methods. *Multimed Tools Appl.* 2023. 82. 5725-5742. DOI: 10.1007/s11042-022-13390-1.
 11. Fuentes A., Yoon S., Kim S.C., Park D.S. A deep robust-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*. 2017. Vol. 17. N9. 2022. DOI: 10.3390/s17092022.
 12. Barbedo J.G.A. Factors influencing the use of deep learning for plant disease recognition. *Biosystems Engineering*. 2018. Vol. 172. 84-91. DOI: 10.1016/j.biosystemseng.2018.05.013.
 13. Старовойтов С.И., Коротченя В.М. Концепция цифровизации почвообрабатывающих машин // *Техника и оборудование для села*. 2021. N8(290). С. 2-6. DOI: 10.33267/2072-9642-2021-8-2-6.
 14. Лобачевский Я.П., Лачуга Ю.Ф., Измайлов А.Ю., Шогенов Ю.Х. Научно-технические достижения агроинженерных научных организаций в условиях цифровой трансформации сельского хозяйства // *Техника и оборудование для села*. 2023. N4(310). С. 2-5. DOI: 10.33267/2072-9642-2023-4-2-5.
 15. Ивашова О.Н., Гавриловская Н.В., Щедрина Е.В. Внедрение цифровых технологий для обеспечения развития сельскохозяйственной отрасли // *Международный журнал гуманитарных и естественных наук*. 2022. N3-2(66). С. 137-139. DOI: 10.24412/2500-1000-2022-3-2-137-139.
 16. Деревянных Е.А., Митрофанова Т.В., Сорокин С.С. и др. О применении искусственного интеллекта в сельском хозяйстве // *Вестник Чувашского государственного аграрного университета*. 2023. N4(27). С. 182-187. DOI: 10.48612/vchd2ut-5bhh-4dkk.
 17. Овчинников А.Ю., Тетерин В.С., Панферов Н.С., Пехнов С.А. Разработка системы оценки трехмерного положения зараженного растения картофеля // *Аграрный научный журнал*. 2025. N3. С. 136-142. DOI: 10.28983/asj.y2025i3pp136-142.
 18. Amit Y., Felzenszwalb P., Girshick R. Object detection. Computer vision: A reference guide. *Springer International Publishing*. 875-883. DOI: 10.1007/978-3-030-63416-2.
 19. Khanam R., Hussain M. YOLOv11: An overview of the key architectural enhancements. *arXiv preprint arXiv*. 2410.17725. 2024. DOI: 10.48550/arXiv.2410.17725.
 20. Jafar A., Bibi N., Naqvi R.A. et al. Revolutionizing agriculture with artificial intelligence: plant disease detection methods, applications, and their limitations. *Frontiers in Plant Science*. 2024. Vol. 15. 1356260. DOI: 10.3389/fpls.2024.1356260.

REFERENCES

1. Borychev S.N., Vladimirov A.F., Koloshein D.V. et al. To the question of research on storing potatoes. *Bulletin of the Ryazan State Agrotechnological University named after P.A. Kostychev*. 2019. N2(42). 129-134 (In Russian). EDN: HIKKNU.
2. Tarkhanova Z.E. Food security of the state: content, significance, threats, food security. *Economics and Management: Problems, Solutions*. 2024. Vol. 6. N10(151). 84-90 (In Russian). DOI: 10.36871/ek.up.p.r.2024.10.06.010.
3. Izmaylov A.Yu., Lobachevskiy Ya.P., Dorokhov A.S. et al. Modern agriculture technologies and equipment – trends of an agritechnika 2019 exhibition. *Tractors and Agricultural Machinery*. 2020. N6. 28-40 (In Russian). DOI: 10.31992/0321-4443-2020-6-28-40.
4. Dorokhov A.S., Sibirev A.V., Ponomarev A.G., Sazonov N.V. Analytical justification of the technological process of the machine for removing infected potato and vegetable crops. *Agrarian Scientific Journal*. 2024. N5. 130-136 (In Russian). DOI: 10.28983/asj.y2024i5pp130-136.
5. Lobachevsky Ya.P., Tsench Yu.S. Principles of forming machine and technology systems for integrated mechanization and automation of technological processes in crop production. *Agricultural Machinery and Technologies*. 2022. Vol. 16. N4. 4-12 (In Russian). DOI: 10.22314/2073-7599-2022-16-4-4-12.
6. Alferyev D.A. Practice of implementing convolutional neural networks in agriculture and agro-industrial complex. *Agricultural and Livestock Technology*. 2020. Vol. 3. N2. 4 (In Russian). DOI: 10.15838/alt.2020.3.2.4.
7. Aksenov A.G., Teterin V.S., Ovchinnikov A.Yu. et al. Using a neural network to identify diseased potato plants. *Agrarian Science*. 2022. N7-8. 167-171 (In Russian). DOI: 10.32634/0869-8155-2022-361-7-8-167-171.
8. Tsench Yu.S., Godlevskaya E.V. Mathematical modeling as a aspect for designing agricultural machines and units (development history of Southern Urals scientific school). *Agricultural Machinery and Technologies*. 2023. Vol. 17. N2. 4-12 (In Russian). DOI: 10.22314/2073-7599-2023-17-2-4-12.
9. Kalichkin V.K. On the need for a paradigm shift in agricultural research (message two). *Siberian Herald of Agricultural Science*. 2024. Vol. 54. N9(310). 102-115 (In Russian).

- Russian). DOI: 10.26898/0370-8799-2024-9-11.
10. Arshaghi A., Ashourian M., Ghabeli L. Potato diseases detection and classification using deep learning methods. *Multimed Tools Appl.* 2023. 82. 5725-5742 (In English). DOI: 10.1007/s11042-022-13390-1.
 11. Fuentes A., Yoon S., Kim S.C., Park D.S. A deep robust-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors.* 2017. Vol. 17. N9. 2022 (In English). DOI: 10.3390/s17092022.
 12. Barbedo J.G.A. Factors influencing the use of deep learning for recognition of plant diseases. *Biosystems Engineering.* 2018. Vol. 172. 84-91 (In English). DOI: 10.1016/J.BIOSYSTEMSENG.2018.05.013.
 13. Starovoitov S.I., Korotchenya V.M. A concept of digitalization of tillage machines. *Machinery and Equipment for Rural Area.* 2021. N8(290). 2-6 (In Russian). DOI: 10.33267/2072-9642-2021-8-2-6.
 14. Lobachevskiy Ya.P., Lachuga Yu.F., Izmaylov A.Yu., Shogenov Yu.Kh. Scientific and technical achievements of agricultural engineering organizations in the context of digital transformation of agriculture. *Machinery and Equipment for Rural Areas.* 2023. N4(310). 2-5 (In Russian). DOI: 10.33267/2072-9642-2023-4-2-5.
 15. Ivashova O.N., Gavrilovskaya N.V., Shchedrina E.V. Introduction of digital technologies to ensure the development of the agricultural industry. *International Journal of Humanities and Natural Sciences.* 2022. N3-2(66). 137-139 (In Russian). DOI: 10.24412/2500-1000-2022-3-2-137-139.
 16. Derevyannykh E.A., Mitrofanova T.V., Sorokin S.S. et al. On the application of artificial intelligence in agriculture. *Vestnik Chuvash State Agrarian University.* 2023. N4(27). 182-187 (In Russian). DOI: 10.48612/vchd2ut-5bhh-4dkk.
 17. Ovchinnikov A.Yu., Teterin V.S., Panferov N.S., Pekhnov S.A. Development of a system for assessing the three-dimensional position of an infected potato plant. *Agrarian Scientific Journal.* 2025. N3. 136-142 (In Russian). DOI: 10.28983/asj.y2025i3pp136-142.
 18. Amit Yu., Felzenshvalb P., Girshik R. Object detection. Computer vision: a reference guide. *Springer International Publishing.* 2021. 875-883 (In English). DOI: 10.1007/978-3-030-63416-2.
 19. Khanam R., Hussain M. YOLOv11: An overview of the key architectural enhancements. *arXiv preprint arXiv.* 2410.17725.2024 (In English). DOI: 10.48550/arXiv.2410.17725.
 20. Jafar A., Bibi N., Naqvi R.A. et al. Revolutionizing agriculture with artificial intelligence: plant disease detection methods, applications, and their limitations. *Frontiers in Plant Science.* 2024. Vol. 15. 1356260 (In English). DOI: 10.3389/fpls.2024.1356260.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest

The authors declare no conflict of interest.

Заявленный вклад соавторов:

Сибирев А.В. – общее руководство, постановка задач исследования, научное редактирование текста статьи; Овчинников А.Ю. – подготовка текста, сбор материалов, анализ литературных данных, формирование выводов; Тетерин В.С. – редактирование и доработка текста, анализ литературных данных, формирование выводов; Панферов Н.С. – сбор материалов, доработка текста, анализ литературных данных; Пехнов С.А. – сбор материалов, подготовка текста, анализ литературных данных.
Авторы прочитали и одобрили окончательный вариант рукописи.

Coauthors' contribution:

Sibirev A.V. – general supervision, formulation of research objectives, scientific editing of the manuscript; Ovchinnikov A.Yu. – manuscript preparation, data collection, literature analysis, formulation of conclusions; Teterin V.S. – manuscript editing, manuscript revision, literature analysis, formulation of conclusions; Panferov N.S. – data collection, manuscript revision, literature analysis; Pekhnov S.A. – data collection, manuscript preparation, literature analysis.
The authors read and approved the final manuscript.

Статья поступила в редакцию
Статья принята к публикации

The paper was submitted to the Editorial Office on
The paper was accepted for publication on

04.09.2025
26.11.2025