

# ТЕХНИКА И ТЕХНОЛОГИИ АПК

ОРИГИНАЛЬНАЯ СТАТЬЯ

УДК 631.356

<https://doi.org/10.26897/2687-1149-2025-4-4-14>



## Разработка элементов цифровой системы идентификации почвенных комков от клубней картофеля картофелеуборочного комбайна

*А.С. Дорохов<sup>1</sup>, М.Н. Ерохин<sup>2</sup>, А.В. Сибирёв<sup>3✉</sup>, М.А. Мосяков<sup>4</sup>, Д.Н. Кынев<sup>5</sup>*

<sup>1,3,4,5</sup> Федеральный научный агроинженерный центр ВИМ; г. Москва, Россия

<sup>2</sup> Российский государственный аграрный университет – МСХА имени К.А. Тимирязева; г. Москва, Россия

<sup>1</sup> dorokhov.vim@yandex.ru; <https://orcid.org/0000-0002-4758-3843>

<sup>2</sup> n.erohin@rgau-msha.ru; <https://orcid.org/0000-0001-6573-0950>

<sup>3</sup> sibirev2011@yandex.ru<sup>✉</sup>; <https://orcid.org/0000-0002-9442-2276>

<sup>4</sup> maks.mosyakov@yandex.ru; <https://orcid.org/0000-0002-5151-7312>

<sup>5</sup> dnkynev@mail.ru; <https://orcid.org/0000-0001-3448-6842>

**Аннотация.** Оснащение элементами автоматизации механических устройств очистки не в полной мере обеспечивает качество очистки товарной продукции от механических примесей. Внедрение системы цифровой идентификации разделяемых биологических объектов от механических примесей на основе гиперспектрального отражения поможет решить данную проблему. Исследования проведены с целью изучения подходов по обработке данных гиперспектрального отражения клубней картофеля и почвенных комков использованием модели нейронной сети YOLOv8 цифровой системы идентификации почвенных комков от клубней картофеля картофелеуборочного комбайна. Разработали конструктивную схему картофелеуборочного комбайна с цифровой системой идентификации биологических объектов на основе гиперспектрального отражения клубней картофеля и распознавания почвенных комков в автоматизированном режиме. Распознавание клубней картофеля и комков почвы на изображениях выполнили с помощью обученных моделей с выделением областей поражения. Получили кривые оценки точности и полноты распознавания комков почвы в диапазоне длин волн 500...700 нм. Оптимальный уровень уверенности для моделей нейронных сетей составил 0,28 для комков почвы и 0,37 – для клубней картофеля. Определили параметры расчета метрик бинарной и мультиклассовой классификации разработанных моделей сверточных нейронных сетей на различных диапазонах длин волн по классам «Картофель», «Почва на картофеле» и «Комок почвы». Установили, что при длине волны 600 нм достигается наивысшая средняя точность распознавания комков почвы mAP 0,329 и клубней картофеля mAP 0,407. Полученные гиперспектральные данные обладают значительным потенциалом для точной классификации и распознавания болезней и повреждений на клубнях и могут быть использованы для выявления незначительных изменений в состоянии клубней. Точность неинвазивного распознавания комков почвы и клубней картофеля с использованием гиперспектральных изображений сравнима с точностью экспертов-людей (отклонение – не более 11,3%).

**Ключевые слова:** цифровая система идентификации; почва; картофель; картофелеуборочный комбайн; распознавание клубней картофеля; точность распознавания

**Финансирование.** Исследования выполнены при финансовой поддержке Российского научного фонда конкурса 2022 г. «Проведение исследований научными коллективами под руководством молодых ученых» Президентской программы научных проектов, реализуемых ведущими учеными, в том числе молодыми учеными, № 22-76-10002.

**Для цитирования:** Дорохов А.С., Ерохин М.Н., Сибирёв А.В., Мосяков М.А., Кынев Д.Н. Разработка элементов цифровой системы идентификации почвенных комков от клубней картофеля картофелеуборочного комбайна // Агроинженерия. 2025. Т. 27, № 4. С. 4-14. <https://doi.org/10.26897/2687-1149-2025-4-4-14>

## ORIGINAL ARTICLE

## Development of elements of a digital system for identifying soil lumps and separating them from potato tubers in a potato harvester

A.S. Dorokhov<sup>1</sup>, M.N. Erokhin<sup>2</sup>, A.V. Sibirev<sup>3</sup>✉, M.A. Mosyakov<sup>4</sup>, D.N. Kynev<sup>5</sup>

<sup>1,3,4,5</sup> Federal Scientific Agroengineering Center VIM; Moscow, Russia

<sup>2</sup> Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; Moscow, Russia

<sup>1</sup> dorokhov.vim@yandex.ru; <https://orcid.org/0000-0002-4758-3843>

<sup>2</sup> n.erohin@rgau-msha.ru; <https://orcid.org/0000-0001-6573-0950>

<sup>3</sup> sibirev2011@yandex.ru✉; <https://orcid.org/0000-0002-9442-2276>

<sup>4</sup> maks.mosyakov@yandex.ru; <https://orcid.org/0000-0002-5151-7312>

<sup>5</sup> dnkynev@mail.ru; <https://orcid.org/0000-0001-3448-6842>

**Abstract.** Equipping mechanical cleaning devices with automation elements does not fully ensure the quality of cleaning commercial products from mechanical impurities. A possible solution is a system of digital identification of separated biological objects from mechanical impurities based on hyperspectral reflection. The authors carried out research to study approaches to processing hyperspectral reflection data of potato tubers and soil clods using the model of neural network YOLOv8 digital system of identification of soil clods mixed with potato tubers in a potato harvester. They have developed a structural scheme of a potato harvester with a digital system of identification of biological objects based on the hyperspectral reflection of potato tubers and recognition of soil clods in an automated mode. Potato tubers and soil clods in the images were recognized using trained models with the selection of lesion areas. The authors obtained curves of accuracy and completeness of soil clods recognition in the wavelength range between 500 and 700 nm. The optimal confidence level for neural network models was 0.28 for soil clods and 0.37 for potato tubers. The authors determined the calculation parameters of binary and multiclass classification metrics of the developed convolutional neural network models at different wavelength ranges for the classes “Potatoes”, “Soil on potatoes”, and “Soil clods”. The authors found that the highest average recognition accuracy for soil clods of mAP 0.329 and that for potato tubers of mAP 0.407 was recorded at a wavelength of 600 nm. The hyperspectral data obtained can significantly increase the accuracy of classification and recognition of diseases and lesions on tubers and can be used to identify minor changes in tuber condition. The accuracy of non-invasive recognition of soil clods and potato tubers using hyperspectral images is comparable to that of human experts (with a deviation of no more than 11.3%).

**Keywords:** digital identification system; potatoes; potato harvester; recognition of potato tubers; accuracy of recognition

**Funding:** The research was carried out with the financial support of the Russian Science Foundation of the 2022 contest “Conducting research by scientific groups led by young scientists” of the Presidential Program of research projects implemented by lead researchers, including young scientists No. 22-76-10002.

**For citation:** Dorokhov A.S., Erokhin M.N., Sibirev A.V., Mosyakov M.A., Kynev D.N. Development of elements of a digital system for identifying soil lumps and separating them from potato tubers in a potato harvester. *Agricultural Engineering (Moscow)*. 2025;27(4):4-14 (In Russ.). <https://doi.org/10.26897/2687-1149-2025-4-4-14>

### Введение

Современное сельскохозяйственное производство предъявляет повышенные требования к качеству и безопасности выполнения технологических операций в условиях роста биологических угроз и распространения инфекционных заболеваний. Одной из ключевых задач в картофелеводстве становится своевременное выявление и удаление поврежденных зараженных клубней картофеля, оказывающих отрицательное влияние на урожайность и сохранность здорового посадочного материала [1, 2].

Анализ современных решений в области автоматизации позволяет выделить растущий интерес

к применению систем автоматического позиционирования и исполнительных механизмов, способных обеспечивать точную локализацию и удаление отдельных биологических объектов, не соответствующих сортовым или фитосанитарным требованиям [3-5].

Особое внимание уделяется совершенствованию систем первичной сепарации клубней картофеля от почвы, эффективность работы которых оказывает непосредственное влияние на производительность и точность удаления механических примесей [6]. Вместе с тем остаются недостаточно исследованными аспекты взаимодействия клубней и элементов сепарирующих устройств.

Разработка автоматизированного устройства с цифровой системой управления требует оптимизации кинематических параметров рабочих органов и комплексного подхода, включающего в себя моделирование процессов взаимодействия механических и биологических компонентов [7]. Однако совершенствование механических устройств очистки оснащением элементами автоматизации не в полной мере позволяет обеспечить качество очистки товарной продукции от механических примесей. Следовательно, для обнаружения поврежденных участков клубней картофеля и распознавания почвенных комков необходимо обеспечить выполнение комплексных мероприятий по повышению уровня автоматизированного контроля и управления процессом сепарации от почвенных примесей внедрением систем цифровой идентификации разделяемых биологических объектов от механических примесей на основе гиперспектрального отражения.

**Цель исследований:** изучение подходов по обработке данных гиперспектрального отражения клубней картофеля и почвенных комков с использованием модели нейронной сети YOLOv8 (You Only Look Once version 8) цифровой системы идентификации почвенных комков от клубней картофеля картофелеуборочного комбайна.

### Материалы и методы

В исследованиях протестировали различные подходы к обработке данных гиперспектрального отражения для обнаружения поврежденных участков клубней картофеля и распознавания почвенных комков с использованием различных методов [8, 9].

Для обработки полученных гиперспектральных изображений комков почвы и клубней картофеля в ортогональной плоскости на оптической линии использовали современную модель нейронной сети YOLOv8 (You Only Look Once version 8) [10-12].

Как и в предыдущих версиях моделей YOLO (YOLOv1-v7), YOLOv8 использует сверточные нейронные сети для обнаружения объектов. Однако модель YOLOv8 имеет ряд усовершенствований, обеспечивающих более высокую точность и скорость работы. YOLOv8 использует более сложную архитектуру, которая включает в себя дополнительные блоки и более 100 сверточных слоев, комбинации сверточных слоев, слоев объединения, слоев активации, слоев нормализации и слоев потерь.

Трансферное обучение заключалось в использовании предварительно обученной модели YOLOv8 на стандартных наборах данных для задачи обнаружения объектов – таких, как COCO (Common Objects in Context), ImageNet, Pascal VOC.

Для обучения нейронной сети подготовлен набор данных (dataset) изображений пораженных биологических объектов (клубней картофеля) и различных по физико-механическим свойствам комков почвы. Сбор набора данных провели путем гиперспектральной съемки камерой Specim IQ изображений комков почвы и клубней картофеля в диапазоне длин волн от 400 до 1000 нм. Фокусировка камеры на исследуемых образцах комков почвы и клубнях картофеля осуществлялась в автоматическом режиме. Освещение во время съемки составляло 100000...120000 лк. Спектральное разрешение (FWHM) полученных изображений составляло 7 нм, пространственная дискретизация – 512 пикселей. Для аннотирования набора данных, выполнения процесса разметки изображений выделили три класса для распознавания объектов: класс «Late-blight» (картофель), класс «Rhizoctoniosis» (почва на картофеле), класс «Rot» (комки почвы). Разметку объектов проводили с использованием прямоугольников – это процесс обведения интересующих объектов на изображении прямоугольниками с указанием соответствующего класса [13].

### Результаты и их обсуждение

В ФГБНУ ФНАЦ ВИМ разработана конструктивная схема картофелеуборочного комбайна для повышения качества очистки клубней картофеля от почвенных комков в автоматизированном режиме с совершенствованием системы цифровой идентификации разделяемых биологических объектов от механических примесей на основе гиперспектрального отражения, обнаружения клубней картофеля и распознавания почвенных комков<sup>1</sup> (рис. 1).

Картофелеуборочный комбайн с цифровой системой идентификации состоит из рамы, копирующего катка-диаболо, плоского секционного лемеха, пассивных плоских обрезных дисков, приемного сепарирующего пруткового элеватора, элеватора переноса продукта, выносной горки, элеватора основного сепарирующего пруткового, активных встряхивающих устройств при наличии блока управления, связанного с исполнительным механизмом подъема задней части элеватора переноса продукта, а его полотно выполнено поперечно-пальчатом и снабжено датчиками массы, связанными с блоком управления.

Отличительной особенностью разрабатываемого картофелеуборочного комбайна является цифровая система идентификации биологических объектов.

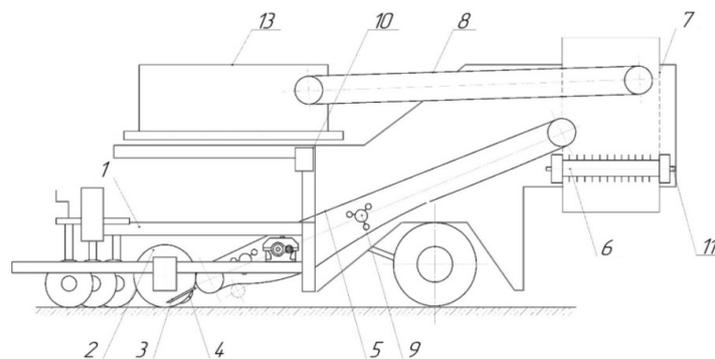
<sup>1</sup> Патент № 2799653 С1 Российская Федерация, МПК А01D17/22. Машина для уборки корнеплодов, картофеля и лука: № 2023101961: заявл. 17.02.2023; Опубл. 07.07.2023 / А.С. Дорохов, А.В. Сибирёв, А.Г. Аксенов [и др.].

Картофелеуборочный комбайн с цифровой системой сепарации работает следующим образом.

При поступательном движении картофелеуборочного комбайна по полю плоские подрезные диски 4 обеспечивают разрезание почвенного слоя при синхронизации извлечения клубненосного пласта секционным лемехом 3. Далее клубненосный ворох последовательно проходит через сепарирующую систему приемного элеватора 5 и элеватора переноса 6, после прохождения поверхности которых выполняется отделение от механических примесей. Под поверхностью пруткового элеватора 5 расположены встряхиватели 9, обеспечивающие интенсификацию очистки клубненосного вороха за счет встряхивания полотна.

Увеличение массы клубненосного вороха на поверхности пруткового элеватора 5 контролируется датчиком массы 12, управляющее воздействие от которого передается на блок 10 и далее, последовательно, на исполнительный механизм, обеспечивающий перемещение полотна выше или ниже установленного предельного значения угла его наклона в диапазоне 10...15 град. Предварительно очищенная продукция поступает на выносную пальчатую горку 7 и обеспечивает перемещение на основной прутковый элеватор 8, после прохождения которого поступает в устройство загрузки.

Схема цифровой системы идентификации разделяемых биологических объектов картофелеуборочного комбайна представлена на рисунке 2.

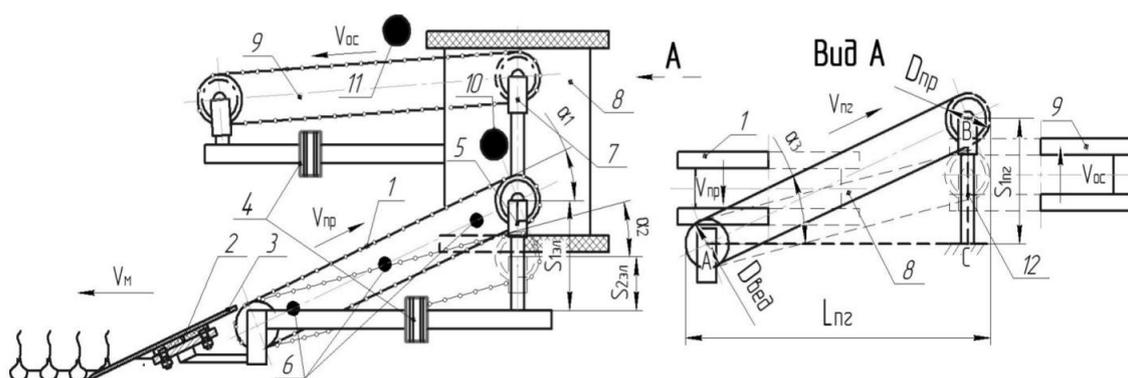


**Рис. 1. Конструктивно-технологическая схема картофелеуборочного комбайна с цифровой системой идентификации:**

- 1 – рама; 2 – каток-диаболо; 3 – плоский секционный лемех; 4 – диск обрезной; 5 – приемный элеватор;
- 6 – элеватор переноса; 7 – горка выносная; 8 – основной элеватор; 9 – встряхиватель; 10 – блок управления;
- 11 – механизм исполнительный; 12 – датчик массы; 13 – бункер-накопитель

**Fig. 1. Design and technological scheme of a potato harvester with the digital identification system:**

- 1 – frame; 2 – diablo roller; 3 – flat sectional share; 4 – trimming disk; 5 – receiving elevator;
- 6 – product transfer elevator; 7 – remote slide; 8 – main elevator; 9 – shaker; 10 – control unit; 11 – actuator; 12 – mass sensor



**Рис. 2. Конструктивно-технологическая схема цифровой системы идентификации биологических объектов картофелеуборочного комбайна:**

- 1 – приемный прутковый элеватор; 2 – лемех подкапывающий; 3 – датчик веса подкапывающего лемеха;
- 4 – микроконтроллер; 5 – опорная стойка приемного пруткового элеватора; 6 – датчик инерционный;
- 7 – опорная стойка основного пруткового элеватора; 8 – выносная пальчатая горка;
- 9 – основной прутковый элеватор; 10, 11 – приемник инфракрасного излучения; 12 – электроцилиндр

**Fig. 2. Design and technological scheme of the digital system for identification of biological objects of a potato harvester:**

- 1 – receiving rod elevator; 2 – digging share; 3 – digging share weight sensor; 4 – microcontroller;
- 5 – support post of the receiving rod elevator; 6 – inertial sensor; 7 – support post of the main rod elevator;
- 8 – remote finger-shaped slide; 9 – main rod elevator; 10, 11 – infrared radiation receiver; 12 – electric cylinder

Над приемным прутковым элеватором 1 установлен приемник инфракрасного излучения 10 (определитель сгуживания вороха), который передает сигнал на электронный блок управления 4 (микроконтроллер) скоростью перемещения картофелеуборочного агрегата.

При превышении заданной толщины вороха на основном прутковом элеваторе 9 изменяется скорость движения агрегата вплоть до полной его остановки, исключая тем самым сгуживание клубненосной массы.

Над местом падения клубней на основном прутковом элеваторе 9 (задняя часть) установлен приемник инфракрасного излучения 11 (определитель примесей). Последний связан с электронным блоком, выход которого соединен с электромагнитными клапанами управления электроцилиндром 12, меняющим угол наклона выносной пальчатой горки 8. В зависимости от наличия на основном прутковом элеваторе 9 почвенных комков либо их отсутствия приемник инфракрасного излучения 11 передает сигнал на гидрораспределитель и при помощи электроцилиндра 12 определяет необходимый наклон выносной пальчатой горки 8, чтобы клубни, выделившиеся из почвы, скатывались с горки 8 на основной прутковий элеватор 9 с минимальным количеством почвенных комков.

Почвенные комки разрушаются при ударе о поверхность пальчатой горки 8. При этом клубни, находившиеся в комках почвы, высвобождаются, а мелкая почва просеивается на убранное поле. Высвободившиеся клубни и остатки примесей с поверхности пальчатой горки 8 попадают на основной прутковий элеватор 9.

На основном прутковом элеваторе 9 клубни перемещаются двухручьевым ленточным транспортером на выгрузной транспортер (на схеме не показан) и далее – в рядом идущий транспорт.

Для разработки вариантов распознавания отличительных признаков комков почвы и клубней картофеля, а также для получения отражающей способности поверхности и внутренних тканей клубня картофеля при различных макроповреждениях выполнялось распознавание объектов в потоке вращательного движения оптической ортогональной системой гиперспектрального сканирования. Обработка изображений осуществлялась с применением искусственных нейронных сетей.

Процесс съемки выполняли в такой последовательности: 1) закрепляли гиперспектральную камеру ОСИ-F на штативе оптической системы идентификации, настраивали фокус; 2) размещали под объективом камеры эталонный объект, прилагаемый

к устройству сканирования; 3) настраивали камеру на съемку по времени и по количеству кадров сканирования биологического объекта.

Полученный набор данных с помощью программного средства Gelion разделили на три выборки по длинам волн 500, 600 и 700 нм (рис. 3).

Построили карту Hitmap (карта интенсивности), помогающую понять, как используемые модели анализируют и интерпретируют входные данные и какие части изображения они считают наиболее информативными и релевантными (рис. 4).

Для получения правильной оценки качества обучаемой модели данные сбалансировали во всех выборках методом Oversampling (увеличение выборки).

Для увеличения объема обучающей выборки, улучшения производительности модели сверточной нейронной сети провели аугментацию данных. На основе существующих изображений получили новые, используя следующие инструменты: горизонтальный и вертикальный поворот (flip: horizontal, vertical); вращение на угол, выбранный в пределах  $-15^\circ \dots +15^\circ$  (rotation); искажение в пределах  $-15^\circ \dots +15^\circ$  (Shear); размытие 2,5 пикселя (Blur); изменение яркости от  $-25\%$  до  $+25\%$  (Brightness); случайное добавление шума, введение изменений в пиксели изображения в количестве до 5% (Noise) (рис. 5).

Добавление разнообразия в обучающие данные с помощью аугментации изображений позволяет модели нейронной сети адаптироваться и быть более устойчивой к «артефактам» и «шумам» на кадрах, что особенно важно в обработке реальных данных при распознавании клубней картофеля.

Для оценки точности прогноза идентификации комков почвы и клубней картофеля произвели расчет средней абсолютной ошибки (Mean Absolute Percentage Error, MAPE) анализируемой модели нейронной сети, используя формулу:

$$MAPE = \frac{1}{n} \sum_{i=1}^k \left| \frac{\Phi_i - \Pi_i}{\Phi_i} \right|,$$

где  $\Phi_i$  – фактическое количество изображений классов «Late-blight» (картофель), «Rhizoctoniosis» (почва на картофеле) и Spot (комков почвы) на тестовой выборке (классифицированных экспертами-агрономами визуальным методом), шт.;  $\Pi_i$  – количество изображений классов «Late-blight» (картофель), «Rhizoctoniosis» (почва на картофеле) и Spot (комков почвы), верно классифицированных с помощью модели сверточной нейронной сети, шт.

Кроме того, полученные результаты исследований подвергали оценке по метрикам Precision, Recall и F1-score (F1-мера).

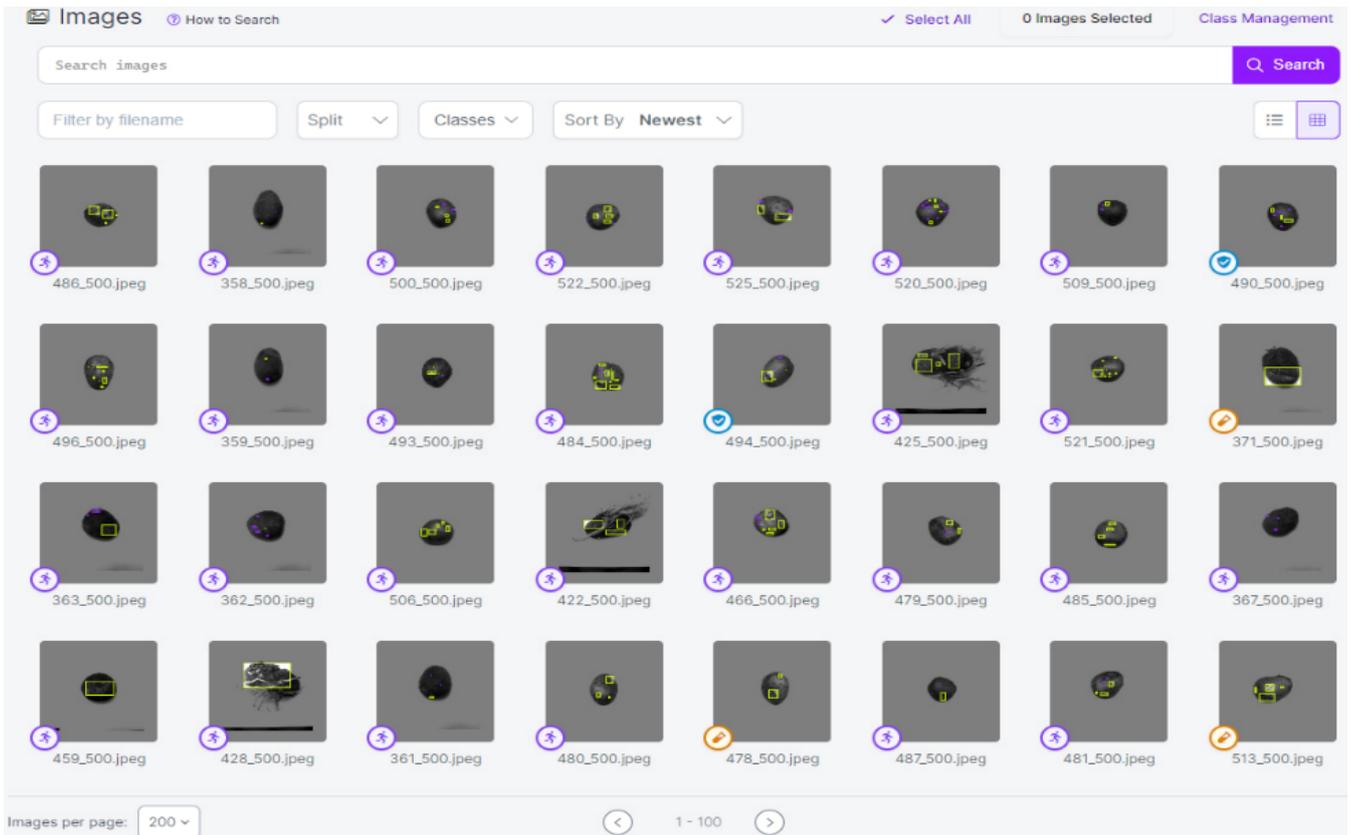


Рис. 3. Размеченный набор данных (dataset)

Fig. 3. Labeled dataset

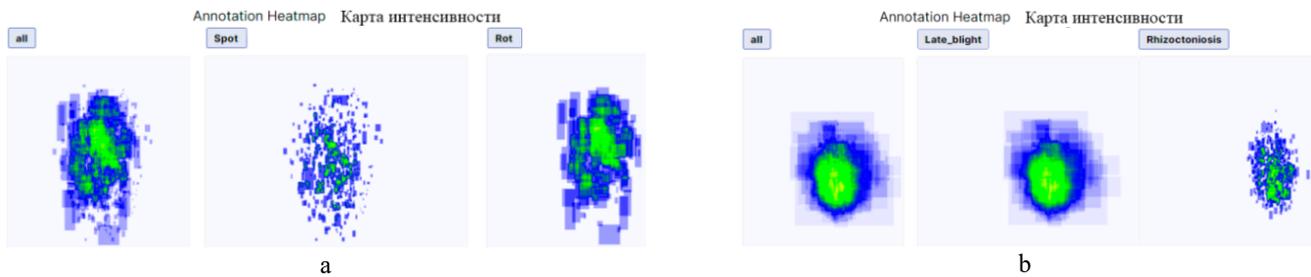


Рис. 4. Hitmap-карта гиперспектральных изображений:

a – комки почвы; b – клубни картофеля

Fig. 4. Hitmap of hyperspectral images:

a – soil clods, b – potato tubers

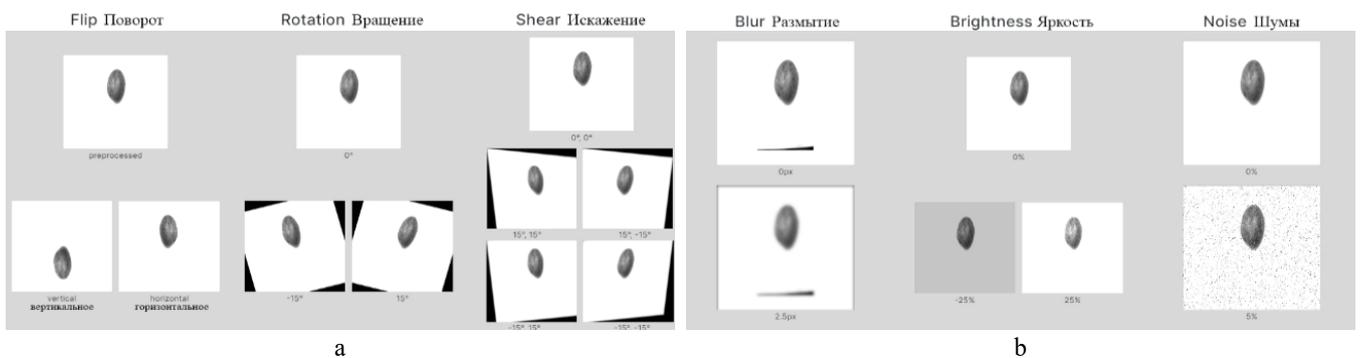


Рис. 5. Пример аугментации набора данных при  $\lambda = 500$  нм:

a – комки почвы; b – клубни картофеля

Fig. 5. Example of dataset augmentation  $\lambda = 500$  nm:

a – soil clods; b – potato tubers

Метрика Precision показывает долю правильно определенных положительных объектов относительно всех объектов, которые классификатор определил как положительные:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

Метрика Recall выявляет долю правильно определенных положительных объектов относительно всех положительных объектов в данных:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

где TP (True Positive) – количество правильно определенных объектов как положительных; FP (False Positive) – количество неправильно определенных объектов как положительных; FN (False Negative) – количество неправильно определенных объектов как отрицательных.

Меру точности и полноты классификационной модели определили с помощью метрики F1-score (F1-мера), представляющей собой гармоническое среднее между точностью (Precision) и полнотой (Recall) модели и использующейся для оценки качества бинарной классификации:

$$\text{F1-score} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

Для оценки вероятности того, что модель правильно определила на изображении область поражения болезнями на клубнях картофеля, использовали показатель Confidence (уверенность). В модели YOLOv8 Confidence представлен как значение вероятности присутствия объекта классификации в bounding box (в прямоугольнике), а также вероятности правильной классификации этого объекта.

Показатель уверенности определили по формуле:

$$\text{Confidence} = \text{Pr}(\text{object}) \cdot \text{IOU}(\text{bbox}, \text{object}),$$

где Pr(object) – вероятность наличия объекта в рамке (bounding box); IOU(bbox, object) – значение метрики Intersection over Union (IoU) между рамкой и реальным объектом в ней.

Для выявления ошибок и несоответствий в разметке, оценки того, насколько хорошо размеченный объект совпадает с его реальным положением на изображении, провели проверку на пересечение объектов, использовали известную метрику IoU (Intersection over Union).

Произвели вычисление координат прямоугольника (bounding box), полностью окружающего объект на изображении. Затем эти координаты использовали для вычисления площади выделенной области. Метрику IoU вычислили как отношение площади пересечения к площади объединения

ограничивающего прямоугольника размеченного и реального объекта:

$$\text{IoU} = \frac{\text{intersection area}}{\text{union area}},$$

где intersection area – площадь пересечения между прямоугольником размеченного объекта и прямоугольником реального объекта, dpi (количество точек на дюйм); union area – площадь объединения прямоугольника размеченного и реального объекта, dpi.

В результате проведенных исследований обучили 6 моделей сверточных нейронных сетей YOLOv8 на длинах волн 500, 600 и 700 нм обучающего набора данных.

Примеры областей распознавания клубней картофеля на изображениях с помощью обученных моделей с выделением областей поражения в ограничивающую рамку представлены на рисунке 6.

Для оценки полученных значений точности и полноты при изменении порога, для принятия решения построили кривые Precision-Recall (точность-полнота) при распознавании клубней картофеля (рис. 7).

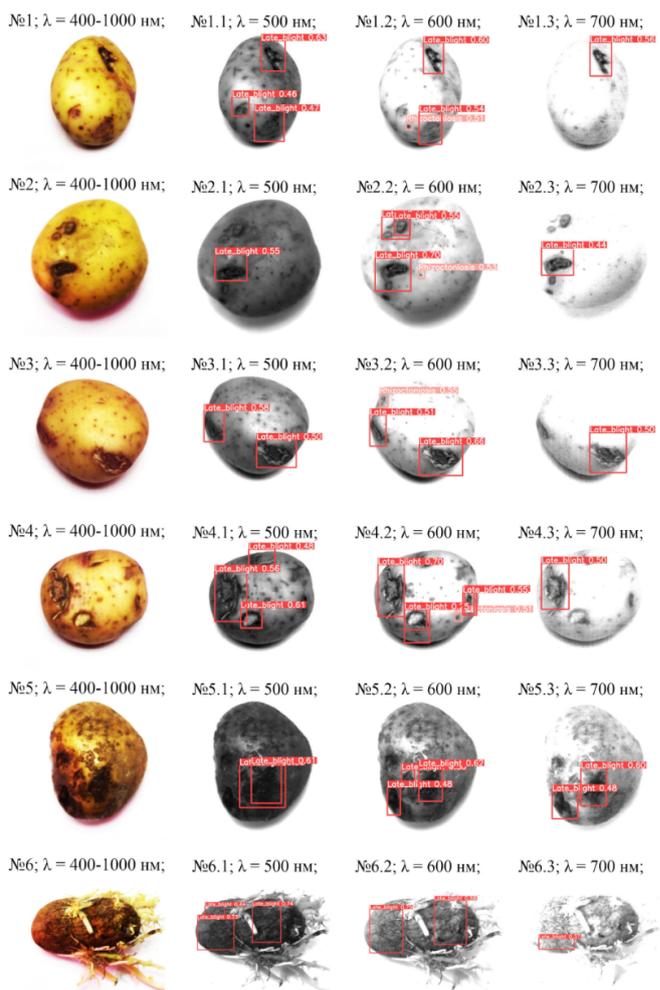


Рис. 6. Примеры распознавания областей поражения болезнями

Fig. 6. Examples of the recognition of disease-affected areas

Анализ графиков Precision-Recall позволил установить порог классификации, равный 0,38, который обеспечивает наилучшее соотношение между точностью и полнотой при распознавании болезней клубней картофеля.

Для оценки качества работы моделей нейронных сетей построили кривые Precision-Confidence и Recall-Confidence, отражающие зависимость точности и полноты предсказаний моделей от уровня уверенности, используемого для принятия решения о наличии объектов распознавания на изображениях (рис. 8).

F1-Confidence график показывает, как модель реагирует на различные уровни шума или наличие выбросов в данных. Полученный Вох-Eрoch график отображает изменение метрики mAP, которая

оценивает качество определения координат ограничивающих рамок объектов на каждой эпохе обучения модели. Вох-Eрoch график позволил определить оптимальное количество эпох обучения, при котором достигается наилучшее качество определения координат ограничивающих рамок объектов. Общее время обучения модели для распознавания комков почвы с длиной волны  $\lambda = 500$  нм при использовании центрального процессора CPU составило 23 ч 17 мин 15 с; с  $\lambda = 600$  нм – 24 ч 36 мин 35 с; с  $\lambda = 700$  нм – 22 ч 32 мин 36 с. Общее время обучения модели для распознавания клубней картофеля с длиной волны  $\lambda = 500$  нм при использовании CPU составило 24 ч 27 мин 20 с; с  $\lambda = 600$  нм – 25 ч 14 мин 35 с; с  $\lambda = 700$  нм – 23 ч 38 мин 12 с.

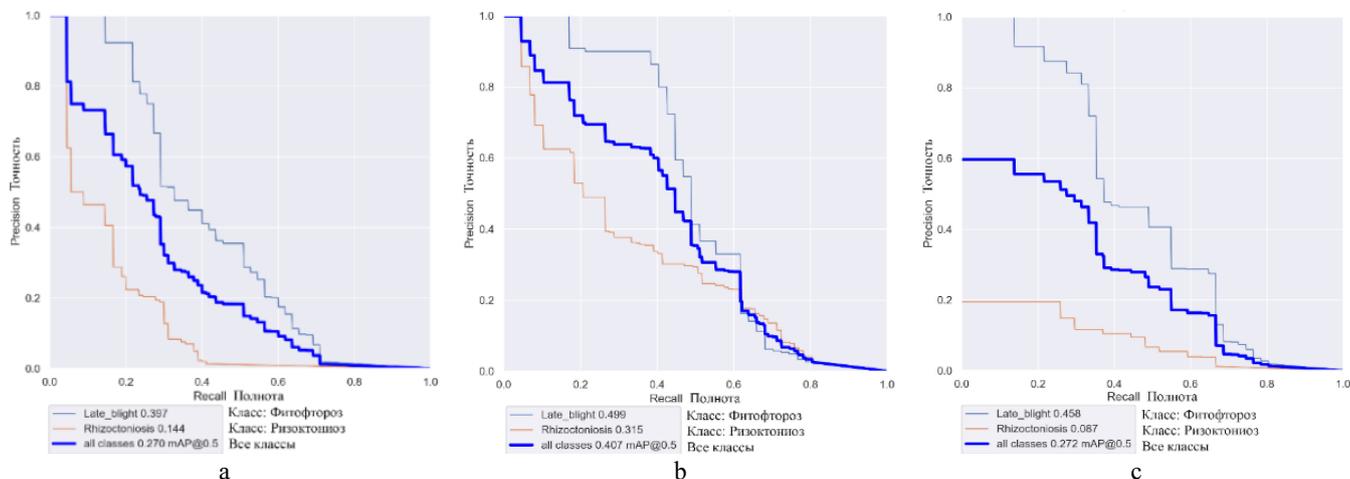


Рис. 7. Кривая оценки точности и полноты Precision-Recall при распознавании клубней картофеля: а)  $\lambda = 500$  нм; б)  $\lambda = 600$  нм; в)  $\lambda = 700$  нм

Fig. 7. Precision-Recall curve for potato tuber recognition: а)  $\lambda = 500$  нм; б)  $\lambda = 600$  нм; в)  $\lambda = 700$  нм

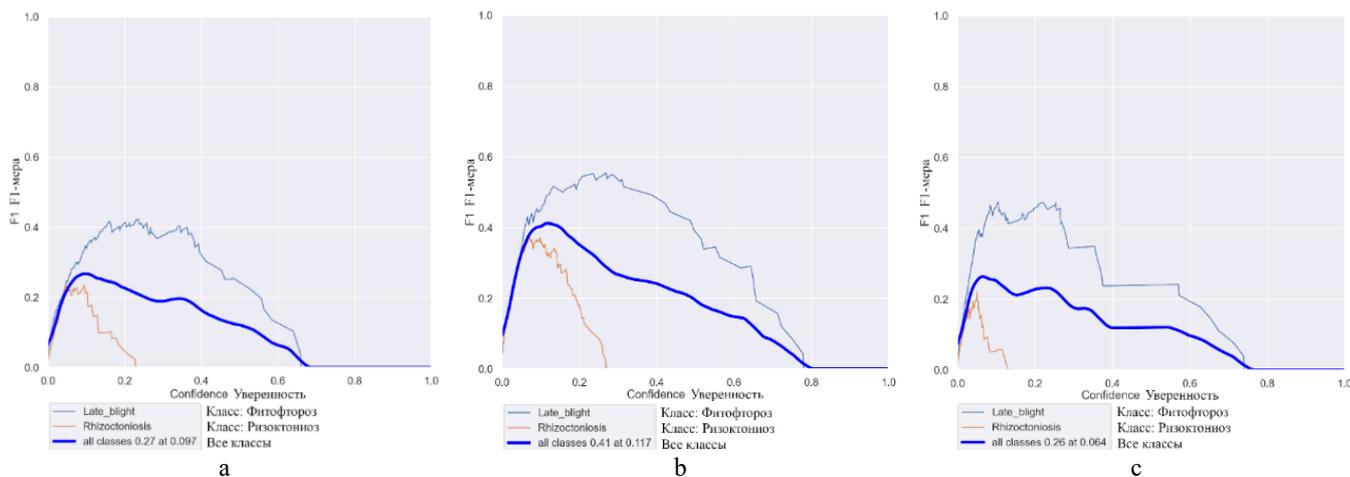


Рис. 8. Кривые оценки качества работы моделей нейронных сетей F1-Confidence при распознавании клубней картофеля: а)  $\lambda = 500$  нм; б)  $\lambda = 600$  нм; в)  $\lambda = 700$  нм

Fig. 8. Performance evaluation curves of F1-Confidence neural network models for potato tuber recognition: а)  $\lambda = 500$  нм; б)  $\lambda = 600$  нм; в)  $\lambda = 700$  нм

Анализ полученных графиков позволил установить оптимальные параметры настройки модели сверточной нейронной сети YOLOv8, выбрать порог уверенности, на котором модель показывает оптимальную точность и сбалансированную полноту с количеством обнаруженных объектов [12].

В результате проведенных исследований определили конфигурацию алгоритма машинного обучения модели YOLOv8 для распознавания областей комков почвы и клубней картофеля классов «Late-blight» (картофель), «Rhizoctoniosis» (почва на картофеле) и Spot (комки почвы): скорость обучения (learning rate) – 0,01 LR (learning rate); количество эпох (epochs) – 83; размер мини-пакета (batch size) – 16.

Коэффициенты трех основных метрик для каждого индивидуального класса и общего набора данных в диапазонах длин волн 500, 600 и 700 нм представлены в таблице 1.

Анализ полученных результатов позволил установить наиболее эффективное значение длины волны  $\lambda = 600$  нм, при которой достигается наивысшая средняя точность распознавания комков почвы mAP 0,329 и клубней картофеля mAP 0,407.

Результаты расчетов средней абсолютной ошибки модели нейронной сети YOLOv8 представлены в таблице 2.

Среднее абсолютное отклонение результатов распознавания разработанной моделью сверточной нейронной сети (длина волны  $\lambda = 600$  нм) изображений клубней картофеля, пораженных болезнями, от визуально идентифицированных экспертами-агрономами, не превысило 11,3%.

Искусственное увеличение объема обучающей выборки (изображений комков почвы и клубней картофеля, пораженных болезнями), использование таких инструментов, как горизонтальный и вертикальный повороты, вращение на заданный угол, искажение, размытие, изменение яркости и случайное добавление шума, позволили существенно повысить качество обучения нейронной сети, помогли адаптировать систему к реальным условиям определения биологических объектов, повысили точность обнаружения признаков поражения болезнями на 16% по сравнению с набором данных без увеличения объема выборки [13].

Определение клубней картофеля, пораженных заболеваниями, выполнялось с целью формирования базы данных, синхронизации полученных результатов исследований в технологии послеуборочной обработки картофеля и дальнейшего совершенствования системы идентификации.

Таблица 1  
Результаты расчета метрик бинарной и мультиклассовой классификации разработанных моделей сверточных нейронных сетей на различных диапазонах длин волн

Table 1  
Results of calculating the metrics of binary and multiclass classification of the developed models of convolutional neural networks for different wavelength ranges

Класс <i>Class</i>	Метрика точности <i>Precision matrix</i>	Метрика полноты <i>Recall matrix</i>	Метрика средней точности <i>mAP matrix</i>
«Late-blight» (картофель) / «Late-blight» (Potato)	0,261	0,314	0,283
«Spot» (комки почвы) / «Spot» (Soil Clod)	0,284	0,169	0,202
Все классы / All classes	0,304	0,157	0,277
Модель сверточной нейронной сети $\lambda = 500$ нм, клубни картофеля / Model of convolutional neural network $\lambda = 500$ nm, potato tubers			
«Late-blight» (картофель) / «Late-blight» (Potato)	0,270	0,527	0,397
«Spot» (комки почвы) / «Spot» (Soil Clod)	0,430	0,100	0,144
Все классы / All classes	0,353	0,314	0,270
Модель сверточной нейронной сети $\lambda = 600$ нм, клубни картофеля / Model of convolutional neural network $\lambda = 600$ nm, potato tubers			
«Late-blight» (картофель) / «Late-blight» (Potato)	0,491	0,489	0,499
«Spot» (комки почвы) / «Spot» (Soil Clod)	0,364	0,297	0,315
Все классы / All classes	0,428	0,393	0,407
Модель сверточной нейронной сети $\lambda = 700$ нм, клубни картофеля / Model of convolutional neural network $\lambda = 700$ nm, potato tubers			
«Late-blight» (картофель) / «Late-blight» (Potato)	0,367	0,549	0,458
«Spot» (комки почвы) / «Spot» (Soil Clod)	0,115	0,058	0,087
Все классы / All classes	0,241	0,304	0,272

Таблица 2

Средняя абсолютная ошибка разработанных моделей сверточных нейронных сетей на различных диапазонах длин волн

Table 2

Average absolute error of the developed models of convolutional neural networks on different wavelength ranges

Класс <i>Class</i>	Количество изображений тестовой выборки, шт. <i>Number of images of the test sample, pcs.</i>	Количество изображений, верно классифицированных с помощью модели сверточной нейронной сети, шт. <i>Number of images correctly classified using the convolutional neural network model, pcs.</i>	Средняя абсолютная ошибка, % <i>Average absolute error, %</i>
<b>Модель сверточной нейронной сети <math>\lambda = 500</math> нм, клубни картофеля / Model of convolutional neural network <math>\lambda = 500</math> nm, potato tubers</b>			
«Late-blight» (картофель) / «Late-blight» (Potato)	150	129	14,00
«Spot» (комоч почвы) / «Spot» (Soil Clod)	150	125	16,67
Все классы / All classes	300	254	15,33
<b>Модель сверточной нейронной сети <math>\lambda = 600</math> нм, клубни картофеля / Model of convolutional neural network <math>\lambda = 600</math> nm, potato tubers</b>			
«Late-blight» (картофель) / «Late-blight» (Potato)	150	137	8,67
«Spot» (комоч почвы) / «Spot» (Soil Clod)	150	130	13,30
Все классы / All classes	300	267	11,00
<b>Модель сверточной нейронной сети <math>\lambda = 700</math> нм, клубни картофеля / Model of convolutional neural network <math>\lambda = 700</math> nm, potato tubers</b>			
«Late-blight» (картофель) / «Late-blight» (Potato)	150	132	12,00
«Spot» (комоч почвы) / «Spot» (Soil Clod)	150	124	17,33
Все классы / All classes	300	256	14,67

### Выводы

1. Разработана конструктивная схема картофелеуборочного комбайна для повышения качества очистки клубней картофеля от почвенных комков, в автоматизированном режиме с совершенствованием системы цифровой идентификации разделяемых биологических объектов от механических примесей, на основе гиперспектрального отражения обнаружения клубней картофеля и распознавания почвенных комков.

2. Выполнено формирование параметрической базы данных клубней картофеля и комков почвы с формированием файлов: JPEG (стандарт сжатия цифрового изображения, определенный в ИСО/МЭК 10918-1); TIFF с разрешением не менее 300 dpi

и цветовым пространством в RGB-диапазоне с занимаемой площадью не менее 35% площади изображения и размером цифровых фотографий не менее  $3602 \times 2480$  пикселей при отсутствии засвеченных участков, резких теней и контрастов.

3. Неинвазивное распознавание клубней картофеля и комков почвы с использованием гиперспектральных изображений возможно с точностью, сравнимой с точностью экспертов-людей (отклонение – не более 11,3%).

4. Необходимость разработки высокопроизводительных алгоритмов и программных решений для обработки и интерпретации гиперспектральных данных является ключевой составляющей исследовательской работы в данной области.

### Список источников / References

- Cao T., Wang Y., Chen J. Analysis and simulation of potato combine harvesting machine. *Communications, Signal Processing, and Systems. Lecture Notes in Electrical Engineering*, 2022;879:556-563. [https://doi.org/10.1007/978-981-19-0386-1\\_70](https://doi.org/10.1007/978-981-19-0386-1_70)
- Dai F., Guo X.H., Zhao W. et al. Design and experiment of canvas belt combined operation machine for potato digging and plastic film collecting. *Transactions of the Chinese Society for Agricultural Machinery*. 2018;49(3):104-113. <https://doi.org/10.6041/j.issn.1000-1298.2018.03.012>
- Wang L., Liu F., Wang Q. et al. Design of a spring-finger potato picker and an experimental study of its picking performance. *Agriculture*. 2023;13(5):945. <https://doi.org/10.3390/agriculture13050945>
- Mu G., Wang W., Zhang T. et al. Design and experiment with a double-roller sweet potato vine harvester. *Agriculture*. 2022;12(10):1559. <https://doi.org/10.3390/agriculture12101559>
- Pasaman B., Zakharchuk V. The determination of the parameters of a ploughshare-rotor potato digger. *Econtechmod. An International Quarterly Journal*. 2012;01(2):43-47.
- Бышов Н.В., Якутин Н.Н., Ковешников Р.Ю. и др. Модернизация копателя КСТ-1,4 // Вестник Рязанского государственного агротехнологического университета им. П.А. Костычева. 2016. № 2. С. 75-78. EDN: WYJNSX
- Byshov N.V., Yakutin N.N., Koveshnikov R.Yu. et al. Modernization of digging machine KST-1.4. *Bulletin of the Ryazan State Agrotechnological University named after P.A. Kostychev*. 2016;2:75-78. (In Russ.)
- Indraja D., Ajkhilesh J., Vishal P. et al. A review paper based on design and development of an onion harvesting machine. *Journal of Information and Computational Science*. 2020;9(12):333-337.

8. Khura T., Mani I., Srivastava A. Design and development of tractor-drawn onion (*Allium cepa*) harvester. *Indian Journal of Agricultural Sciences*. 2011;81(6):528-532.

9. El-Rahman A., Magda M. Development and performance evaluation of a simple grading machine suitable for onion sets. *Journal of Soil Sciences and Agricultural Engineering*. 2011;2(2):213-226. <https://doi.org/10.21608/jssae.2011.55418>

10. Lu K., Xie S., Gai X., Ji X. Design and experiment of toggle lever-type potato picker. *Agriculture*. 2024;14:826. <https://doi.org/10.21608/jssae.2011.55418>

11. Lü J.Q., Sun H., Dui H., Peng M.M., Yu J.Y. Design and experiment on conveyor separation device of potato digger under heavy

soil condition. *Transactions of the CSAM*. 2017;48(11):146-155. <https://doi.org/10.6041/j.issn.1000-1298.2017.11.018>

12. Jia B., Sun W., Zhao Z. et al. Design and field test of a remotely controlled self-propelled potato harvester with manual sorting platform. *American Journal of Potato Research*. 2023;100:193-209. <https://doi.org/10.1007/s12230-023-09909-3>

13. Dorokhov A.S., Sibirev A.V., Aksenov A.G. The results of field tests of an onion set harvesting machine equipped with a shaker arrangement asymmetrical bar elevator. *Engineering Technologies and Systems*. 2020;30(1):133-148. <https://doi.org/10.15507/2658-4123.030.202001.133-148>

### Информация об авторах

<sup>1</sup> **Дорохов Алексей Семёнович**, д-р техн. наук, профессор, главный научный сотрудник, академик РАН; [dorokhov.vim@yandex.ru](mailto:dorokhov.vim@yandex.ru); SPIN-код: 6711-8971, AuthorID: 550644; <https://orcid.org/0000-0002-4758-3843>

<sup>2</sup> **Ерохин Михаил Никитьевич**, д-р техн. наук, профессор, академик РАН; [n.erohin@rgau-msha.ru](mailto:n.erohin@rgau-msha.ru); SPIN-код: 3499-4405, AuthorID: 626708; <https://orcid.org/0000-0001-6573-0950>

<sup>3</sup> **Сибирёв Алексей Викторович**, д-р техн. наук, главный научный сотрудник; [sibirev2011@yandex.ru](mailto:sibirev2011@yandex.ru); SPIN-код: 1726-5356, AuthorID: 794047; <https://orcid.org/0000-0002-9442-2276>

<sup>4</sup> **Мосяков Максим Александрович**, канд. техн. наук, ведущий научный сотрудник; [maks.mosyakov@yandex.ru](mailto:maks.mosyakov@yandex.ru); SPIN-код: 3196-9443, AuthorID: 812688; <https://orcid.org/0000-0002-5151-7312>

<sup>5</sup> **Кынев Дмитрий Николаевич**, младший научный сотрудник, аспирант; [dnkynev@mail.ru](mailto:dnkynev@mail.ru); SPIN-код: 7681-9750, AuthorID: 959997

<sup>1,3,4,5</sup> Федеральный научный агроинженерный центр ВИМ; 109428, Российская Федерация, г. Москва, 1-й Институтский проезд, 5

<sup>2</sup> Российский государственный аграрный университет – МСХА имени К.А. Тимирязева; 127434, г. Москва, Тимирязевская ул., 49

### Вклад авторов

А.С. Дорохов – формулирование основной концепции исследований;

М.Н. Ерохин – разработка методологии исследований;

А.В. Сибирёв – описание результатов и формирование выводов исследований, подготовка начального варианта текста;

М.А. Мосяков – представление результатов, подготовка графических материалов;

Д.А. Кынев – программная реализация алгоритма.

### Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов и несут ответственность за плагиат

Статья поступила 05.03.2025, после рецензирования и доработки 06.05.2025; принята к публикации 07.05.2025

### Author Information

**Aleksei S. Dorokhov**<sup>1</sup>, Full Member of the Russian Academy of Sciences, DSc (Eng), Professor; [dorokhov.vim@yandex.ru](mailto:dorokhov.vim@yandex.ru); <https://orcid.org/0000-0002-4758-3843>

**Mikhail N. Erokhin**<sup>2</sup>, Full Member of the Russian Academy of Sciences, DSc (Eng), Professor; [n.erohin@rgau-msha.ru](mailto:n.erohin@rgau-msha.ru); <https://orcid.org/0000-0001-6573-0950>

**Aleksei V. Sibirev**<sup>3</sup>, DSc (Eng), Chief Research Engineer; [sibirev2011@yandex.ru](mailto:sibirev2011@yandex.ru); <https://orcid.org/0000-0002-9442-2276>

**Maksim A. Mosyakov**<sup>4</sup>, CSc (Eng), [maks.mosyakov@yandex.ru](mailto:maks.mosyakov@yandex.ru); <https://orcid.org/0000-0002-5151-7312>

**Dmitriy N. Kynev**<sup>5</sup>, Junior Research Engineer, postgraduate student

<sup>1,3,4,5</sup> Federal Scientific Agroengineering Center VIM; 109428, Russia, Moscow, 1st Institutskiy Proezd Str., 5

<sup>2</sup> Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; 127434, Russia, Moscow, Timiryazevskaya Str., 49

### Author Contribution

A.S. Dorokhov – conceptualization;

M.N. Erokhin – research methodology;

A.V. Sibirev – description of the results (data curation), conclusions, writing – original draft;

M.A. Mosyakov – presentation of the results, visualization;

D.A. Kynev – software (algorithm implementation)

### Conflict of interests

The authors declare no conflict of interests regarding the publication of this article and bear equal responsibility for plagiarism

Received 05.03.2025; Revised 06.05.2025; Accepted 07.05.2025