



Показатели качества работы автоматизированной машины для ухода за растениями картофеля в селекции и семеноводстве

Николай Викторович Сазонов,
кандидат технических наук,
старший научный сотрудник,
e-mail: sazonov_nikolay@mail.ru;
Максим Александрович Мосяков,
кандидат технических наук,
старший научный сотрудник,
e-mail: maks.mosyakov@yandex.ru;
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;
Мария Михайловна Годяева,
аспирант, младший научный сотрудник,
e-mail: airrune@yandex.ru;
Максим Сергеевич Трунов,
аспирант, специалист,
e-mail: makstrunov1998@mail.ru

Федеральный научный агроинженерный центр ВИМ, Москва, Российская Федерация

Работа выполнена при государственной поддержке РНФ конкурса 2023 года «Проведение исследований научными группами под руководством молодых ученых» Президентской программы исследовательских проектов, реализуемых ведущими учеными, в том числе молодыми учеными № 23-76-10062.

Реферат. При выращивании картофеля в целях селекции и семеноводства важно как можно раньше выявить зараженные растения. В связи с этим необходимо провести комплекс работ по созданию цифровой системы автоматизированного выявления и распознавания здоровых и зараженных растений. (*Цель исследования*) Определить закономерности изменения показателей качества работы машины для ухода за растениями картофеля. (*Материалы и методы*) Исследования проведены на площади селекционно-опытной делянки. Разработана система критериев для оценки идентификации зараженных растений. (*Результаты и обсуждение*) Определена требуемая достоверность измерительной операции системы технического зрения машины и прогнозирования текущего состояния системы идентификации зараженных растений с учетом статистической информации о распределении косвенного параметра (наличие признаков заражения на внутренней стороне листа растения) и погрешности его измерений. Достоверность работы системы идентификации зараженных растений зависит от точности технических средств измерений состояния растений, методов измерений, программного обеспечения обработки полученных измерений, других параметров. (*Выводы*) Управление измерительной информацией заключается в обоснованном выборе косвенного параметра, обеспечивающего точность распознавания зараженных растений с доверительным интервалом вероятности 0,95. Установлено, что точность классификации растений на первой эпохе обучения системы идентификации зараженных растений составила 0,797 или 79,7 процентов для всех растений. Корректность распознавания заболевших растений составляла 0,607 или 60,7 процентов. Стоит отметить, что уже на данной эпохе корректность распознавания здоровых растений достигала 99,9 процентов.

Ключевые слова: картофель, уход за растениями, комплекс машин, система технического зрения, программный комплекс.

■ **Для цитирования:** Сазонов Н.В., Мосяков М.А., Тетерин В.С., Панферов Н.С., Годяева М.М., Трунов М.С. Показатели качества работы автоматизированной машины для ухода за растениями картофеля в селекции и семеноводстве // *Сельскохозяйственные машины и технологии*. Т. 18. №1. С. 60-67. DOI: 10.22314/2073-7599-2024-18-1-60-67. EDN: MAJKNM.

Scientific article

Quality Metrics of Automated Machinery in Potato Plant Cultivation for Breeding and Seed Production

Nikolay V. Sazonov,
Ph.D.(Eng.), senior researcher,
e-mail: sazonov_nikolay@mail.ru;

Maxim A. Mosyakov,
Ph.D.(Eng.), senior researcher,
e-mail: maks.mosyakov@yandex.ru;

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;**Maria M. Godyaeva,**graduate student, junior researcher,
e-mail: airrune@yandex.ru;**Maxim S. Trunov,**graduate student, specialist,
e-mail: makstrunov1998@mail.ru

Federal Scientific Agroengineering Center VIM, Moscow, Russian Federation

The work is supported by the Grant of the Russian Science Foundation for the 2023 competition «Conducting research by scientific groups under the guidance of young scientists» of the Presidential program of research projects implemented by leading scientists, including young scientists No. 23-76-10062.

Abstract. The paper notes the significance of promptly identifying infected plants when cultivating potatoes for breeding and seed production. Consequently, there is a need to undertake a series of initiatives aimed at developing a digital system for automated detection and recognition of both healthy and infected plants. (*Research purpose*) The research aims to determine the patterns of changes in the quality indicators of the machinery employed in cultivating potato plants. (*Materials and methods*) The research was carried out on the area of the selection-experimental plot. A system of criteria was developed to evaluate the identification of infected plants. (*Results and discussion*) The research assisted in identifying the required reliability of the measuring operation for the machine vision system and aided in predicting its current state for identifying infected plants. This was achieved by analyzing statistical data on the distribution of the indirect parameter (indications of infection on the inside of the plant leaf) and considering the margin of error in its measurements. The reliability of the system for identifying infected plants depends on the precision of technical instruments used to gauge the plant's condition, the methodologies employed in measurement, the software utilized for processing the obtained data, and other parameters. (*Conclusions*) Measurement information management involves making a judicious selection of an indirect parameter that guarantees the precision of identifying infected plants with a confidence interval of 0.95. It is revealed that in the initial training epoch of the infected plant identification system, the accuracy of plant classification stood at 0.797, equivalent to 79.7 percent for all plants. The correctness of infected plant recognition was 0.607 or 60.7 percent. Moreover, the accuracy of correctly identifying infected plants was determined to be 0.607, or 60.7 percent. Notably, by this epoch, the accuracy of recognizing healthy plants had already reached 99.9 percent.

Keywords: potatoes, plant cultivation, machine complex, technical vision system, software package.

■ For citation: Sazonov N.V., Mosyakov M.A., Teterin V.S., Panferov N.S., Godyaeva M.M., Trunov M.S. Quality metrics of automated machinery in potato plant cultivation for breeding and seed production. *Agricultural machinery and technologies*. 2024. Vol. 18. N1. 60-67 (In Russian). DOI: 10.22314/2073-7599-2024-18-1-60-67. EDN: MAJKNM.

Получение стабильного высокого и качественного урожая в различных почвенно-климатических условиях требует создания и адаптации новых сортов, что сопряжено с рядом специфических трудно механизлируемых операций полевой стадии производства и обработки урожая на селекционно-опытных делянках [1]. Стратегическое решение проблемы механизации процессов селекции, сортоиспытания и первичного семеноводства овощных культур в России путем закупки техники за рубежом нецелесообразно из-за высокой стоимости машин, комплектующих и других расходных материалов [2].

В настоящее время предлагаются различные машинно-технологические комплексы для удаления зараженных растений картофеля и овощных культур, выполняющие рабочие операции по запланированному алгоритму [3]. Первую прочистку посадки картофеля проводят после появления пол-

ных всходов, когда растения достигают высоты 15-20 см, удаляются кусты, пораженные черной ножкой, ризоктониозом и вирусами. Машина, обрабатывая посадки, должна распознавать зараженные растения [4]. Необходимо выполнить комплекс работ, направленных на создание цифровой системы для автоматизированного выявления и распознавания здоровых и зараженных растений [5].

Цель исследования – определение закономерностей изменения показателей качества работы машины для ухода за растениями картофеля в селекционно-семеноводческих хозяйствах.

Материалы и методы. При движении по учетной делянке машина осуществляет распознавание и извлечение из почвы зараженных кустов картофеля для последующей утилизации. Весь технологический процесс проходит без влияния человеческого фактора, что вызывает необходимость определять изменения показателей качества работы машины

при использовании в ее конструкции элементов автоматизации и роботизации [6].

Полноту идентификации зараженных растений машины для сорто-фитопрочистки определяли по формуле [7]:

$$v_K = \frac{v_{\Pi}^I - v_{\Pi}^K}{v_{\Pi}^I} \cdot 100\%, \quad (1)$$

где v_{Π}^I и v_{Π}^K – количество идентифицированных и неидентифицированных зараженных растений на площади учетной делянки, шт.

Полнота извлечения зараженных растений [13-16]

$$P_K = \frac{P_{\Pi}^I - P_{\Pi}^K}{P_{\Pi}^I} \cdot 100\% \quad (2)$$

где P_{Π}^I и P_{Π}^K – количество извлеченных из почвы и неизвлеченных зараженных растений на площади учетной делянки, шт.

Результаты и обсуждение. Точность идентификации зараженных растений обусловлена:

- требуемой достоверностью измерительной операции системы технического зрения машины;
- прогнозированием текущего состояния системы идентификации зараженных растений (СИ) с учетом статистической информации о распределении и погрешности измерений косвенного параметра ($KП$), в данном случае – это наличие признаков заражения на внутренней стороне листа растения ($KП_1$) [8].

Достоверность работы системы идентификации зараженных растений зависит от точности технических средств измерений состояния растений (v_{K1}), метода измерений (v_{K2}), программного обеспечения обработки измерений (v_{K3}), а также от n -ого параметра эффективности выбора косвенного параметра, эксплуатационного допуска на них ($ЭД$), функционального веса системы идентификации в системе работы машины. Управление полезностью измерительной информации заключается в обоснованном выборе косвенного параметра, обеспечивающего точность распознавания зараженных растений с доверительным интервалом вероятности $p = 0,95$ (Измайлов А.Ю., Гришин А.А., Гришин А.П., Лобачевский Я.П. Экспертные системы интеллектуальной автоматизации технических средств сельскохозяйственного назначения. Инновационное развитие АПК России на базе интеллектуальных машинных технологий. М.: ВНИИ механизации сельского хозяйства, 2014. С. 379-382).

При этом необходимо решить ряд частных задач: определить точность методов измерений, их достоверность, точность прогнозирования зараженных растений.

С точки зрения выбора косвенного параметра ($KП$) все показатели можно разделить на метрологические ($ПМ$) и эксплуатационные ($ПЭ$):

$$\begin{cases} P_M = \{D_{i,j}, \delta_j, \delta_{Mj}, \delta_{CUj}, \delta_{PRj}; \\ P_E = \{f_{\Delta}(x); f_{CP}(x); \sigma_{\Delta}^2; \end{cases}$$

$$\Delta P_{KПj}, f_{\Delta}(y), f_{KП}(y), \sigma_{\Delta}^2\}, \quad (3)$$

$$P_{СПП.Р}; \Delta P_{СПД.ОП}; N; T_H \}$$

где δ_1 – погрешность экспертизы; δ_{M1} – погрешность метода измерения $KП_j$; $\delta_{CП1}$ – погрешность средства измерения $KП_j$; $\delta_{ПР1}$ – погрешность прогнозирования состояния (ПС); $f_{KП}(y)$ – допуск на результат измерения $KП_j$; $f_{\Delta}(y)$ – дифференциальный закон распределения вероятности (ДЗРВ) погрешности измерения $KП_j$; $f_{KП}(y)$ – ДЗРВ значений $KП_j$; $f_{KП}(y)$ – ДЗРВ погрешности измерений ($ПМ_i$); $f_{CП}(x)$ – ДЗРВ $СП_i$; σ_{Δ}^2 и $\sigma_{CП}^2$ – дисперсии погрешности измерений $KП_j$ и $СП_i$; $P_{СПП.Р}$ – предельное значение $СП_i$; $\Delta P_{СПД.ОП}$ – допустимое отклонение $СП_i$; N – число измеренных характеристик растений; T_H – наработка ОЭ.

Предельное значение $СП_i$ приводится в нормативной документации (назначается по технико-экономическому критерию или по критерию требуемой вероятности безотказной работы). Допустимое отклонение $СП_i$ и наработка T_H назначаются в нормативной документации в зависимости от $P_{СПП.Р}$.

Поскольку

$$D = f(P_{СПП.Р}; \Delta P_{СПД.ОП}; T_H), \quad (4)$$

где D – достоверность, то с учетом этих критериев можно управлять полезностью измерительной информации.

Действительно, исходя из физической природы эксплуатационного изменения $СП_i$, до некоторой наработки T_{H1} точность операций измерения $СП_i$ не имеет существенного значения, так как

$$T_H < T_{H1}, \quad (5)$$

то значение $СП_i$ еще значительно отличается от $P_{СПП.Р}$ и даже без контроля с высокой вероятностью можно обеспечить безотказность ОЭ.

Максимальное значение достоверности измерительной информации

$$D_{i,j} = D_{i,jmax} \quad (6)$$

должно быть обеспечено в области T_H , при которых значение $СП_i$ близко к допустимому и предельному, так как принимаемое решение о годности ОЭ к эксплуатации связано с ошибками 1-го и 2-го рода, что приводит к росту издержек.

Из-за изменения показателей ДЗРВ $СП_i$ с течением времени для обеспечения требуемого значения $D_{i,j}$ методы и средства измерений должны иметь различные показатели точности при различной наработке оборудования. ДЗРВ значений $СП$ машин чаще всего является нормальным или описывается законом Вейбулла, а погрешности измерений $KП$

описываются нормальным или равномерным ДЗРВ.

С учетом вышеизложенного требования к точности средств измерений должны формироваться исходя из реальных значений T_{Hmax} или из значений

$$T_H \{f_{СП}(x)|_{max}\}, \quad (7)$$

соответствующих области максимальных значений ДЗРВ $\{f_{СП}(x)|_{max}\} СП_i$.

Источник информации может выдавать дискретные или непрерывные сигналы со средней скоростью (производительностью) источника:

$$R_U = \frac{I_U(\tau)}{\tau}, \quad (8)$$

где $I_U(\tau)$ – производительность источника; τ – среднее количество информации в сообщении, время передачи которого не превышает времени τ ; время передачи одного сообщения τ , секунд (скорость передачи информации, соответствующая передаче двоичной единицы (0;1) за секунды).

В качестве обобщенных параметров переносчика информации (информационного сигнала) можно принять: ширину амплитудно-частотного спектра F_c , отношение сигнал/помеха Q_c , длительность существования τ_c и объем сигнала V_c .

$$Q_c = \log\left(\frac{P_c}{P_n}\right), \quad (9)$$

где P_c и P_n – средние мощности сигнала и помехи.

$$V_c = F_c Q_c \tau_c. \quad (10)$$

Для идентификации зараженных растений картофеля разработан программный комплекс на основе сверточной нейронной сети *ResNet34*, предназначенной для анализа изображений и последующего определения заболевших растений [9]. Используемая нейронная сеть обладает 34 слоями, ее архитектура представлена на рисунке 1.

Традиционная сверточная или полносвязная нейронная сеть будет иметь потерю информации и другие проблемы при передаче данных, в то же время это приведет к исчезновению или всплеску градиента, что в свою очередь способно вызывать проблемы в ее обучении [10]. Нейронная сеть на основе архитектуры *ResNet* в определенной степени решает эту проблему. Она защищает целостность данных, напрямую обходя входную информацию и выводя ее. Всей сети нужно только изучить часть разницы между входом и выходом, что упрощает ее обучение.

Так, структура нейронная сеть *ResNet34* разбита на 4 группы. Первая группа имеет в своем составе три остаточных блока (*рис. 1*).

В представленном остаточном блоке содержится два сверточных слоя, при этом на вход первого сверточного слоя поступает нулевой слой, тензор x . В общем понимании тензором называется N -мерный массив чисел, в данном случае представляющий собой матрицу чисел, характеризующих изображение. Затем после первого слоя вычисляется активация с помощью функции активации *ReLU* (*рис. 2*), в результате полученные выходы нейронов идут на вход следующим нейронам второго сверточного слоя.

ReLU – наиболее часто используемая функция активации в нейронных сетях, особенно в сетях сверточного типа. Для всех положительных значений *ReLU* является линейным (тождественным), для всех отрицательных значений *ReLU* равно нулю.

Вторая, третья и четвертая группы содержат соответственно 4, 5 и 3 остаточных блока. В каждой группе, кроме первой, сверточный фильтр совершает проход по тензору x с шагом два (*stride* = 2 или «/2»).

После каждой группы слоев уменьшается раз-




Рис. 1. Архитектура используемой нейронной сети ResNet34 (слева) и общий вид остаточного блока (справа)
Fig. 1. Architecture of the ResNet34 neural network (left) and general view of the residual block (right)




Рис. 2. График функции активации ReLu

Fig. 2. Rectified Linear Unit (ReLU) activation function graph

мер тензора по высоте и ширине и увеличивается количество фильтров в 2 раза (64, 128, 256, 512). Уменьшение размера тензора необходимо для увеличения рецептивного поля (Receptive Field) в более поздних слоях сети.

На примере человеческого зрения данный принцип работы можно описать следующим образом: вся область, которую может видеть человеческий глаз, называется полем зрения. Зрительная система человека состоит из миллионов нейронов, каждый из которых улавливает разную информацию. Таким образом рецептивное поле нейрона можно определить, как участок всего поля зрения [11].

В структуре нейронной сети ResNet34 в начале каждой группы слоев (кроме первой) можно увидеть остаточный блок с пунктирной связью (рис. 3).

Рассмотрим вторую группу блоков. Первый слой




Рис. 3. Остаточный блок с пунктирной связью: общий вид (слева) и вид блока, характерный для второй группы (справа)

Fig. 3. Residual block with dotted connection: general view (left) and block type typical of the second group (right)

для этой группы блоков характеризуется тем, что, во-первых, шаг всегда равен 2, во-вторых, вдвое больше фильтров, чем в предыдущей группе блоков. Получается, что глубина на входе слоя составляет 64, на выходе из сверточного слоя – 128 и на выходе второго слоя тоже 128, сложность будет заключаться на этапе сложения. Тензор x размером

$W \times H \times R$ должен быть сложен с выходом второго слоя, который имеет размеры $W/2 \times H/2 \times 2R$. Решение этой проблемы заключается в использовании свертки размером 1×1 , которая проходит с шагом 2, количество таких фильтров 128, следовательно, проблема сложения тензоров с разными глубинами R и $2R$ будет решена за счет увеличения количества фильтров. Проблема разной ширины и высоты будет решена за счет шага 2.

Также стоит заметить, что перед первой группой блоков стоит операция Pooling. Задача этой операции – без потери информации уменьшить размер тензора. Pooling с шагом 2 увеличивает рецептивное поле. Процесс вычисления Pooling представлен на рисунке 4.

Последний слой используемой нейронной сети




Рис. 4. Пример проведения операции Pooling для максимального и среднего значений

Fig. 4. An example of the Pooling operation for maximum and average values

полносвязный с 2 нейронами, так как конечным результатом являются 2 класса значений – большие и здоровые кусты картофеля.

Разделение нейронной сети на сверточную и полносвязную части имеет функциональное значение. В частности, задача сверточной части – вычисление «хороших» характеристик от изображения, а полносвязной – принять итоговое решение на основе тензора, пришедшего от сверточной части. Перед полносвязным слоем в 2 нейрона находится Average global pooling – он превращает карту характеристик в одно число [12].

ResNet34 на входе принимает изображение размером 224×224 пикселя в RGB канале, после первого слоя прохода сверткой 7×7 изображение меняет размер на 112×112 пикселей, также пулинг с шагом 2. Во вторую группу блоков изображение заходит размером 28×28 пикселей, в третью – 14×14 пикселей, в четвертую – 7×7 пикселей, и тензор $7 \times 7 \times 512$ превратится в вектор, в котором 512 значений.

Стоит отметить, что для работы с нейронными сетями требуется наличие достаточно больших вычислительных мощностей графического процессо-

ра GPU [13]. Использование именно графических процессоров для обучения нейронных сетей связано в первую очередь с различием архитектуры их построения в сравнении с центральными процессорами CPU. Графические процессоры, благодаря архитектуре своего ядра, эффективно справляются с большим количеством несложных однотипных задач, в связи с чем обладают высокой производительностью.

Обучение нейронных сетей на CPU способно занять несколько месяцев, в то время как графические процессоры с данной задачей способны справиться за несколько дней. При этом GPU обладают меньшим энергопотреблением.

Способность к быстрому обучению нейронных сетей на графических процессорах связаны в первую очередь с их особенностью решать параллельно несколько задач, а сами нейронные сети представляют собой параллельные алгоритмы [14]. Кроме того, графические процессоры оптимизированы для матричных операций и ускоряют их – они необходимы нейронным сетям для получения результата [15].

В связи с этим для реализации нейронной сети, основанной на архитектуре ResNet34, тренировки и испытания ее применимости для определения здоровых и заболевших растений картофеля был использован сервис Google Collaboratory. Данный ресурс представляет собой облачный сервис, позволяющий получить удаленный доступ к машине с подключенной видеокарой.

Для проведения корректной тренировки нейронной сети на изображениях листьев и растений картофеля к фотографиям применялись следующие требования:

- отсутствие на изображениях посторонних объектов;
- постоянная высота, на которой делаются снимки;
- светочувствительность камеры (ISO) настраивается таким образом, чтобы не было белых пятен на изображении (засветов).

В качестве тренировочной выборки была использована библиотека, состоящая из 3731 фотографии заболевших и 1520 фотографий листьев и растений картофеля (рис. 5).

Кроме того, для последующей корректировки весов нейронной сети была подготовлена валидационная выборка для проверки работоспособности модели, состоящая из 480 фотографий здоровых и 1269 фотографий больных растений. По результатам самотестирования была получена матрица ошибок (рис. 6).

Анализ матрицы показывает, что доля ошибочно распознанных изображений валидационной выборки составляет менее 1%, это свидетельствует о высокой работоспособности и корректности распознавания модели.

Кроме того, для определения качества работы про-




Рис. 5. Изображения листа и растения картофеля: сверху – зараженные растения; внизу – здоровые растения
Fig. 5. Images of a potato leaf and plant: top – infected plants; below – healthy plants

Фактический Здоровые	Заболевшие	1736	13
	Здоровые	12	1737
		Прогноз	

Рис. 6. Матрица ошибок

Fig. 6. Error Matrix

граммного комплекса по выявлению заболевших растений картофеля проведена серия испытаний. С этой целью была подготовлена тестовая выборка фотографий, не участвующих в обучении нейронной сети, по 25 изображений здоровых и больных растений (рис. 7).

В исследовании оценивалась точность распе-



Рис. 7. Примеры здоровых (слева) и заболевших (справа) растений из тестовой выборки

Fig. 7. Examples of healthy (left) and infected (right) plants from the test sample

деления растений к той или иной группе. Полученные вероятности заносились в таблицу. На основании полученных данных была построена графическая зависимость показывающая среднее значение




Рис. 8. Зависимость точности распределения от количества пройденных эпох обучения

Fig. 8. Dependence of distribution accuracy on the number of training epochs

точности распределения исходя из количества эпох обучения (рис. 8).

Выводы.

Результаты проведенных исследований позволили установить, что точность классификации растений на первой эпохе обучения идентификации зараженных растений составила 0,797 или 79,7% для всех растений, при этом корректность распознавания заболевших растений составляла 0,607 или 60,7%. Уже на этой эпохе корректность распознавания здоровых растений составляла 99,9%.

С увеличением количества проведенных эпох обучения наблюдается рост корректных распознаваний: уже на четвертой эпохе корректность распознавания для всех растений превышает 99,5%, а на шестой эпохе достигает 99,9% для всех растений и 99,8% для зараженных.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

- Лобачевский Я.П., Дорохов А.С., Сибирев А.В. Современное состояние технологического обеспечения производства овощных культур в Российской Федерации // *Овощи России*. 2023. N5. 5-10. DOI: 10.18619/2072-9146-2023-5-5-17.
- Дорохов А.С., Аксенов А.Г., Сибирев А.В., Пономарев А.Г., Сазонов Н.В. Теоретические предпосылки интенсификации уборки лука-севка // *Сельскохозяйственные машины и технологии*. 2023. N3. С. 85-92. DOI: 10.22314/2073-7599-2023-17-3-85-92.
- Yanykin D.V., Pashin M.O., Simak A.V., et al. Plant photochemistry under glass coated with up conversion luminescent film. *Applied Sciences*. 2022. 12. 7480. DOI: 10.3390/app12157480.
- Golmohammadi A., Bejaei F., Behfar H. Design, development and evaluation of an online potato sorting system using machine vision. *International Journal of Agriculture and Crop Sciences*. 2013. N6. 396-402. DOI: cabdirect.org/cabdirect/abstract/20133372449.
- Lü J.Q., Shang Q.Q., Yang Y. et al. Design optimization and experiment on potato haulm cutter. *Transactions of the CSAM*. 2016. N47(5). 106-114. DOI: 10.1080/0305215X.2016.1164855.
- Dorokhov A., Aksenov A., Sibirev A. et al. Results of laboratory studies of the automated sorting system for root and onion crops. *Agronomy*. 2021. Vol. 11. N6. 1257. DOI: 10.3390/AGRONOMY11061257. EDN: EMOYFO.
- 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. EDN: KIGZDF.
- 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. N16(4). С. 4-12. DOI: 10.22314/2073-7599-2022-16-4-4-12. EDN: IDJFYV.
- Попов В.Д., Валге А.М., Папушин Э.А. Повышение эффективности производства продукции растениеводства с использованием информационных технологий // *Технологии и технические средства механизированного производства продукции растениеводства и животноводства*. 2009. Т. 81. С. 32-39. EDN: THYQKD.
- Измайлов А.Ю., Лобачевский Я.П., Дорохов А.С. и др. Современные технологии и техника для сельского хозяйства - тенденции выставки Agritechnica 2019 // *Тракторы и сельхозмашины*. 2020. N6. С. 28-40. DOI: 10.31992/0321-4443-2020-6-28-40.
- 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.
- Ракутько С.А., Ракутько Е.Н., Медведев Г.В. Разработка экспериментального фитотрона и его применение в исследованиях по энергоэкологии светокультуры // *Сельскохозяйственные машины и технологии*. 2023. Т. 17. N2. С. 40-48. DOI: 10.22314/2073-7599-2023-17-2-40-48.
- Sojka R.E., Horne D.J., Ross C.W., Baker C.J. Subsoiling and surface tillage effects on soil physical properties and for age oat stand and yield. *Soil and Tillage Research*. 1997. N40 (3-4). 25-144. DOI: 10.1016/S0167-1987(96)01075-6.
- Федоренко В.Ф. Тенденции цифровизации и интеллектуализации сельского хозяйства // *Инновации в сельском хозяйстве*. 2019. N1(30). С. 231-241. EDN: IKJJHN.
- Черноиванов В.И. Цифровые технологии в АПК // *Техника и оборудование для села*. 2018. N5. С. 2-4. EDN: XORBJR.

REFERENCES

1. Lobachevsky Ya.P., Dorokhov A.S., Sibirev A.V. The current state of technological support for the production of vegetable crops in the Russian Federation. *Vegetables of Russia*. 2023. N5. 5-10 (In Russian). DOI: 10.18619/2072-9146-2023-5-5-17.
2. Dorokhov A.S., Aksenov A.G., Sibirev A.V. et al. Theoretical prerequisites for intensifying the harvesting of onion sets. *Agricultural Machinery and Technologies*. 2023. N3. 85-92 (In Russian). DOI: 10.22314/2073-7599-2023-17-3-85-92.
3. Yanykin D.V., Pashkin M.O. Simakin A.V. et al. Plant photochemistry under glass coated with upconversion luminescent film. *Applied Sciences*. 2022. 12. 7480 (In English). DOI: 10.3390/app12157480.
4. Golmohammadi A., Bejaei F., Behfar H. Design, development and evaluation of an online potato sorting system using machine vision. *International Journal of Agriculture and Crop Sciences*. 2013. N6. 396-402 (In English). DOI: cabdirect.org/cabdirect/abstract/20133372449.
5. Lü J.Q., Shang Q.Q., Yang Y., et al. Design optimization and experiment on potato haulm cutter. *Transactions on the CSAM*. 2016. N47(5). 106-114 (In English). DOI: 10.1080/0305215X.2016.1164855.
6. Dorokhov A., Aksenov A., Sibirev A., et al. Results of laboratory studies of the automated sorting system for root and onion crops. *Agronomy*. 2021. Vol. 11. N6. 1257 (In English). DOI: 10.3390/AGRONOMY11061257. EDN: EMOYFO.
7. Lobachevsky Ya.P., Lachuga Yu.F., Izmailov A.Yu., Shogenov Yu.Kh. Scientific and technical achievements of agro-engineering scientific 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. EDN: KIGZDF.
8. Lobachevsky Ya.P., Tsench Yu.S. Principles of forming systems of machines and technologies for complex mechanization and automation of technological processes in crop production. *Agricultural Machinery and Technologies*. 2022. N16(4). 4-12 (In Russian). DOI: 10.22314/2073-7599-2022-16-4-4-12. EDN: IDJFYV.
9. Popov V.D., Valge A.M., Papushin E.A. Increasing the efficiency of crop production using information technology. *Technologies and Technical Means of Mechanized Production of Crop and Livestock Products*. 2009. Vol. 81. 32-39 (In Russian). EDN: THYQKD.
10. Izmailov A.Yu., Lobachevsky Ya.P., Dorokhov A.S. et al. Modern technologies and equipment for agriculture - trends at the Agritechnika 2019 exhibition. *Tractors and Agricultural Machinery*. 2020. N6. 28-40 (In Russian). DOI: 10.31992/0321-4443-2020-6-28-40.
11. Tsench Yu.S., Godlevskaya E.V. Mathematical modeling as a tool for designing agricultural machines and units (in relation to the history of the development of the scientific school of the Southern Urals). *Agricultural Machinery and Technologies*. 2023. Vol. 17. N2. 4-12 (In Russian). DOI: 10.22314/2073-7599-2023-17-2-4-12.
12. Rakutko S.A., Rakutko E.N., Medvedev G.V. Development of an experimental phytotron and its application in research on the energy ecology of light culture. *Agricultural Machinery and Technologies*. 2023. Vol. 17. N2. 40-48 (In Russian). DOI: 10.22314/2073-7599-2023-17-2-40-48.
13. Sojka R.E., Horne D.J., Ross C.W., Baker C.J. Subsoiling and surface tillage effects on soil physical properties and forage oat stand and yield. *Soil and Tillage Research*. 1997. N40 (3-4). 25-144 (In English). DOI: 10.1016/S0167-1987(96)01075-6.
14. Fedorenko V.F. Trends in digitalization and intellectualization of agriculture. *Innovations in Agriculture*. 2019. N1(30). 231-241 (In Russian). EDN: IKJJHN.
15. Chernoi Ivanov V.I. Digital technologies in the agro-industrial complex. *Machinery and Equipment for Rural Areas*. 2018. N5. 2-4 (In Russian). EDN: XORBJR.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest

The authors declare no conflict of interest.

Заявленный вклад соавторов:

Сазонов Н.В. – концептуализация, научное руководство;
Мосяков М.А. – концептуализация, научное руководство, методология;

Тетерин В.С. – концептуализация, проведение исследований;
Панферов Н. С. – концептуализация, визуализация;
Годяева М.М. – методология, проведение исследований;
Трунов М.С. – поиск и анализ литературы.

Авторы прочитали и одобрили окончательный вариант рукописи.

Coauthors' contribution:

Sazonov N.V. – conceptualization, scientific guidance;
Mosyakov M.A. – conceptualization, scientific guidance, methodology;

Teterin V.S. – conceptualization, research;
Panferov N. S. – conceptualization, visualization;
Godyaeva M.M. – methodology, research;
Trunov M. S. – literature review.

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

10.01.2024

26.02.2024