

МЕЛИОРАЦИЯ, ВОДНОЕ ХОЗЯЙСТВО И АГРОФИЗИКА

Научная статья

УДК 631.67+004.5

doi: 10.31774/2712-9357-2024-14-2-94-107

Применение методов машинного обучения к построению прогнозных моделей продуктивности многолетних трав при орошении

Сергей Сергеевич Марченко¹, Андрей Евгеньевич Новиков²,
Наталья Ивановна Бурцева³, Сергей Яковлевич Семененко⁴

^{1, 2, 3, 4}Всероссийский научно-исследовательский институт орошаемого земледелия – филиал Федерального научного центра гидротехники и мелиорации имени А. Н. Костякова, Волгоград, Российская Федерация

¹marchenkosergey@mail.ru, <https://orcid.org/0000-0002-2627-6465>

²vnioz@yandex.ru, <https://orcid.org/0000-0002-8051-4786>

³burtseva.ni58@yandex.ru, <https://orcid.org/0000-0002-9787-7321>

⁴sergeysemenenko@list.ru, <https://orcid.org/0000-0001-5992-8127>

Аннотация. Цель: проверить гипотезу о возможности построения прогнозной модели урожайности многолетних трав с использованием методов машинного обучения. Для планирования сельскохозяйственного производства прогнозирование урожайности является одной из важных задач, а при использовании информационных технологий построение прогнозных моделей требует заметно меньше трудозатрат при сохранении или даже повышении точности и адекватности моделей. **Материалы и методы.** В исследовании применялись такие методы научного познания, как анализ и синтез различных уровней, методы подготовки данных для машинного обучения, методы машинного обучения, реализующие модель линейной регрессии и регрессии с помощью решающих деревьев. В качестве основного стека технологий для реализации методов машинного обучения использован популярный язык Python и общедоступные библиотеки анализа и подготовки данных и построения моделей машинного обучения. **Результаты.** Проведена подготовка данных для тренировки модели методами машинного обучения, при этом данные видоизменены без потерь таким образом, что представляют собой исключительно числовые значения. Проведено обучение моделей линейной регрессии и регрессии с помощью решающих деревьев. С помощью стандартных инструментов используемых библиотек вычислена метрика качества моделей, подтвержденная высокими значениями коэффициентов детерминации (соответственно 0,68 и 0,98). **Выводы:** численные значения вклада в модель таких признаков, как пищевой режим (0,176935–0,315269), а также соотношение числа поливов и оросительной нормы (0,056576–0,108139), подтверждают их значимость для условий территории проведения исследований и набора базы данных.

Ключевые слова: машинное обучение, прогноз урожайности, прогнозная модель, многолетние травы

Сведения о научно-исследовательской работе, по результатам которой публикуется статья: статья подготовлена на основании исследований, проведенных в соответствии с государственным заданием FNFR-2022-0005.

Для цитирования: Применение методов машинного обучения к построению прогнозных моделей продуктивности многолетних трав при орошении / С. С. Марченко, А. Е. Новиков, Н. И. Бурцева, С. Я. Семененко // Мелиорация и гидротехника. 2024. Т. 14, № 2. С. 94–107. <https://doi.org/10.31774/2712-9357-2024-14-2-94-107>.

LAND RECLAMATION, WATER MANAGEMENT AND AGROPHYSICS

Original article

Machine learning methods application to the perennial grasses yield forecast model building under irrigation

Sergey S. Marchenko¹, Andrey E. Novikov², Natalia I. Burtseva³,
Sergey Ya. Semenenko⁴

^{1, 2, 3, 4}All-Russian Research Institute of Irrigated Agriculture – branch of the Federal Scientific Center of Hydraulic Engineering and Land Reclamation named after A. N. Kostyakov, Volgograd, Russian Federation

¹marchenkosergey@mail.ru, <https://orcid.org/0000-0002-2627-6465>

²vniiioz@yandex.ru, <https://orcid.org/0000-0002-8051-4786>

³burtseva.ni58@yandex.ru, <https://orcid.org/0000-0002-9787-7321>

⁴sergeysemenenko@list.ru, <https://orcid.org/0000-0001-5992-8127>

Abstract. Purpose: to test the hypothesis on possibility of perennial grasses yield forecast model building using machine learning methods. For agricultural production planning, the yield forecasting is one of the important tasks, and when using information technologies, building forecast models requires significantly less labor while maintaining or even increasing the accuracy and adequacy of the models. **Materials and methods.** Such methods of scientific knowledge as analysis and synthesis of various levels, methods of data preparation for machine learning, machine learning methods implementing a linear regression model and regression using decision trees were used. The popular Python language and publicly available libraries for data analysis and preparation and building machine learning models were used as the main technology stack for implementing machine learning methods. **Results.** The data was prepared for training the model using machine learning methods, and the data was modified without loss in such a way that it represents exclusively numerical values. Linear regression and regression models using decision trees were trained. A metric of model quality confirmed by high values of determination coefficients (0.68 and 0.98, respectively) was calculated, using standard tools from the libraries used. **Conclusions:** numerical values of input of such characteristics as food regime (0.176935–0.315269), as well as the ratio of the number of irrigations and irrigation norms (0.056576–0.108139), into the model, confirm their significance for the conditions of research areas and database collection.

Keywords: machine learning, yield forecast, predictive model, perennial grasses

Information about the research work, on results of which the article is published: the article was prepared on the basis of research conducted in accordance with state assignment FNFR-2022-0005.

For citation: Marchenko S. S., Novikov A. E., Burtseva N. I., Semenenko S. Ya. Machine learning methods application to the perennial grasses yield forecast model building under irrigation. *Land Reclamation and Hydraulic Engineering*. 2024;14(2):94–107. (In Russ.). <https://doi.org/10.31774/2712-9357-2024-14-2-94-107>.

Введение. Российское сельское хозяйство все больше становится цифровым, несмотря на низкую заинтересованность мелких фермерских хозяйств в применении достижений искусственного интеллекта (ИИ) в силу значительных материальных затрат, не субсидируемых государством, и

практически отсутствия специалистов, сочетающих в себе знания технологий сельскохозяйственного производства и технологий ИИ. При этом крупные агрохолдинги постоянно наращивают, до 47 % в год, потенциал использования ИИ и тем самым увеличивают эффективность работы.

Производство продукции на орошаемых землях подвержено большому количеству стабильных и нестабильных физических воздействий, проявляющихся стохастически, что обуславливает необходимость использования метода машинного обучения для построения модели прогноза урожайности и его качества. Данная модель должна учитывать и оперативно вырабатывать управляющие воздействия на основе информации о состоянии нерегулируемых условий (почвенных, метеорологических, гидрогеологических, топографических), регулируемых ресурсах (доступный объем забора воды, трудовых, материально-технических, информационных), наилучших, научно обоснованных технологиях (обработка почвы, семена и система защиты растений, режим увлажнения, способы и техника полива, качество оросительной воды и многое другое). Быстро и точно это может быть сделано только с помощью алгоритмов машинного обучения, но никак невозможно обработать «ручными» методами.

При использовании ландшафтно-адаптивного подхода в системе орошаемого земледелия следует учитывать огромное количество факторов, влияние которых обусловлено тем, как именно решается задача подбора элементов системы земледелия к условиям агроландшафтов с целью их максимального вклада в продуктивность сельскохозяйственных культур и минимизации воздействий неблагоприятных условий с помощью мелиоративных приемов [1, 2].

Волгоградская область находится в так называемой зоне рискованного земледелия, что подразумевает использование специальных технологий для получения устойчивых гарантированных урожаев. В засушливых условиях нашего региона такой специальной технологией является орошение [2, 3].

В качестве гипотезы будем рассматривать утверждение, что на основании методов машинного обучения можно построить адекватную прогнозную модель урожайности многолетних трав.

Сформулируем цель исследования в следующем виде: построить прогнозную модель урожайности на основе методов машинного обучения.

Материалы и методы. Исходными данными для исследования служит база данных по нерегулируемым условиям, регулируемым факторам и урожайности многолетних травосмесей, подготовленная сотрудниками отдела интенсивных технологий возделывания сельскохозяйственных культур ФГБНУ «Всероссийский научно-исследовательский институт орошаемого земледелия». Исследования продукционных процессов многолетних трав проводились для долгосрочных смесей весеннего сева в 2011–2019 гг.

Анализ производился в среде языка программирования Python с использованием библиотек анализа и подготовки данных *pandas*, библиотеки визуализации *matplotlib* и библиотеки машинного обучения *scikit-learn*, которая позволяет решать различные задачи классификации, кластеризации и регрессии.

База данных содержит сведения о виде посева, видовом составе травосмесей, годе использования травостоя, количестве поливов, оросительной норме, пищевом режиме, режиме орошения, соотношении компонентов травосмесей и урожайности (рисунок 1).

В терминах машинного обучения все данные включаются в множество признаков, а урожайность является целевым признаком, или таргетом.

Исходная база данных в формате Microsoft Access прошла предварительную обработку в Microsoft Power BI и для дальнейшего анализа была преобразована в формат csv.

Долгосрочные смеси весеннего посева											
Кл	Поле1	Поле2	Поле3	Поле4	Поле5	Поле6	Поле7	Поле8	Поле9	Поле10	Поле11
1	Год использования травостоя	Режим орошения, % НВ	Количество поливов	Оросительная норма	Соотношение компонентов	Вид посева	Видовой состав травосмесей	Пищевой режим, N	Пищевой режим, P	Пищевой режим, K	Урожайность, т/га зеленой массы
2	первый	70-75	7	2825	бобовые-110, мятликовые-110	черезрядный (каждый компонент в отдельный рядок)	люцерна желтогибридная+клевер белый+козлятник восточный+кострец безостый+ежа сборная	0	0	0	21,8
3	первый	70-75	7	2825	бобовые-110, мятликовые-110	черезрядный (каждый компонент в отдельный рядок)	люцерна желтогибридная+клевер белый+козлятник восточный+кострец безостый+ежа сборная	120	40	55	29,4
4	первый	70-75	7	2825	бобовые-110, мятликовые-110	черезрядный (каждый компонент в отдельный рядок)	люцерна желтогибридная+клевер белый+козлятник восточный+кострец безостый+ежа сборная	165	55	80	37,6
5	первый	70-75	7	2825	бобовые-110, мятликовые-110	черезрядный (каждый компонент в отдельный рядок)	люцерна желтогибридная+клевер белый+козлятник восточный+кострец безостый+овсяница тростниковая	0	0	0	20,3
6	первый	70-75	7	2825	бобовые-110, мятликовые-110	черезрядный (каждый компонент в отдельный рядок)	люцерна желтогибридная+клевер белый+козлятник восточный+кострец безостый+овсяница тростниковая	120	40	55	28,7
7	первый	70-75	7	2825	бобовые-110, мятликовые-110	черезрядный (каждый компонент в отдельный рядок)	люцерна желтогибридная+клевер белый+козлятник восточный+кострец безостый+овсяница тростниковая	165	55	80	36,5
8	первый	70-75	7	2825	бобовые-110, мятликовые-110	черезрядный (каждый компонент в отдельный рядок)	люцерна желтогибридная+клевер белый+козлятник восточный+кострец безостый+овсяница тростн.+ежа сборная	0	0	0	24,4
9	первый	70-75	7	2825	бобовые-110, мятликовые-110	черезрядный (каждый компонент в отдельный рядок)	люцерна желтогибридная+клевер белый+козлятник восточный+кострец безостый+овсяница тростн.+ежа сборная	120	40	55	31,4

Рисунок 1 – Фрагмент базы данных «Долгосрочные смеси весеннего посева»

Figure 1 – Fragment of the database “Long-term mixtures for spring sowing”

В целом, в соответствии с классической схемой машинного обучения [4–6], необходимо осуществить следующие этапы: подготовку данных, которая включает в себя обработку данных, отбор признаков, выделение целевого признака, обучение модели, оценку обученной модели на основании метрики или набора метрик.

Множество признаков включало в себя как числовые и псевдочисловые признаки, например, количество поливов и режим орошения или данные о пищевом режиме, так и категориальные, такие как вид посева или видовой состав травосмесей.

Подготовка данных производилась методами библиотеки `pandas` и включала в себя обработку псевдочисловых признаков, в частности, разделение признака «Режим орошения» на отдельные столбцы, содержащие минимальные и максимальные значения предполивной влажности, или замену символьного порядкового номера года травостоя на числовое значение.

Для трансформации категориальных признаков был использован встроенный в `scikit-learn` общепринятый метод `onehotencoding`, он разбивает признак на некоторое количество столбцов, равное количеству сущностей, которое он содержал до трансформации, с записью значения 1 в соответствующем столбце и строке.

Из-за особенностей составления исходной базы данных пропусков в значениях не было, обработка их не требовалась.

Итоговый очищенный и подготовленный набор данных включал 20 признаков и 252 записи (строки).

Для построения прогнозных моделей были использованы встроенные в `scikit-learn` методы, реализующие регрессионный анализ, `LinearRegression` и `RandomForestRegressor`.

При использовании модели линейной регрессии используемой библиотеки набор данных делился на обучающую (тренировочную) и тестовую выборки последовательно в соотношении 90–10, 85–15, 80–20 и 70–30 %,

а приведенные далее результаты отражают наилучший вариант. В качестве критерия качества модели был использован коэффициент детерминации, который вычислялся встроенными средствами библиотеки `scikit-learn`.

Результаты и обсуждение. Концепция конструирования агрофитоценозов и экологически безопасных технологий возделывания культур основывается на оптимизации сочетания агроклиматических ресурсов региона с биологическими характеристиками растений для более полной реализации потенциала их продуктивности. Это достигается рациональным сочетанием режимов полива и внесения расчетных доз удобрений, оценкой и учетом биологических, возрастных и сортовых характеристик новых интенсивных сортов сельскохозяйственных культур, обеспечивающих производство высококачественной продукции, сохранение плодородия почвы и экологическую безопасность окружающей среды.

В результате многолетних исследований во Всероссийском научно-исследовательском институте орошаемого земледелия для почвенно-климатических условий Нижнего Поволжья были подобраны рациональные сочетания видового состава, размещения компонентов, водного и пищевого режимов почвы для получения запланированных урожаев бобово-мятликовых травосмесей при различных сроках пользования травостоями [7, 8].

При этом в настоящее время во многих отраслях агропромышленной деятельности уже наработаны и эффективно используются приемы одномоментного совместного анализа большого количества факторов для построения прогнозных моделей с достаточной степенью точности на основании методов машинного обучения [9–13].

При обучении на основе модели линейной регрессии `LinearRegression` и получении прогноза признаки набора данных подвергались стандартизации и нормализации. До этих операций влияние признаков на прогноз хаотично и не отражает научный опыт (рисунок 2).




Рисунок 2 – Вклад признаков в прогноз урожайности на основе модели линейной регрессии

Figure 2 – Features contribution to yield forecast based on a linear regression model

Как видно из данных рисунка, наибольший вклад вносят такие признаки, как «Количество поливов», «Год использования травостоя» и «Пищевой режим, К», при этом значение коэффициента детерминации R^2 составляет 0,66.

После стандартизации диаграмма вклада признаков в прогнозную модель выглядит следующим образом (рисунок 3).



Рисунок 3 – Вклад признаков в прогноз урожайности на основе модели линейной регрессии после стандартизации признаков

Figure 3 – Features contribution to yield forecast based on linear regression model after features standardization

Данная диаграмма показывает, что после стандартизации признаков наибольший вклад в прогнозную модель вносит пищевой режим и в мень-

шей степени режим орошения, это более адекватно отражает происходящие производственные процессы. Произведенная обработка признаков также привела к увеличению коэффициента детерминации R^2 , который составил 0,68.

Модель линейной регрессии имеет общий вид:

$$f(x, b) = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n,$$

где b_i – параметры (коэффициенты) регрессии;

x_i – регрессоры (факторы модели);

n – количество факторов модели.

Значения вектора-столбца коэффициентов регрессии представлены в таблице 1, значение свободного члена регрессии равно 38,87.

Таблица 1 – Значения вектора-столбца коэффициентов линейной регрессии

Table 1 – Values of the column vector of linearity regression coefficient

Индекс коэффициента	Значение коэффициента	Индекс коэффициента	Значение коэффициента
1	–5,774011e+00	11	–4,694873e–01
2	–4,973458e+00	12	4,694873e–01
3	4,248154e+00	13	0,000000e+00
4	–1,298178e+02	14	0,000000e+00
5	–2,242943e+01	15	0,000000e+00
6	1,659178e+02	16	5,058457e–02
7	–3,907985e–13	17	7,310321e–01
8	–1,705303e–13	18	1,958804e–01
9	4,973799e–14	19	–1,097229e+00
10	7,815970e–14		

При использовании модели RandomForestRegressor были применены параметры, предлагаемые библиотекой по умолчанию, т. е. количество решающих деревьев равно 100, критерий расщепления – «Пуассон» и т. д. В результате значение коэффициента детерминации получилось равным 0,98, что является очень хорошим показателем для моделей регрессии и соответствует результатам, полученным другими авторами [14].

При этом распределение вкладов признаков в модель выглядит следующим образом (таблица 2).

Таблица 2 – Вклад признаков в прогнозную регрессионную модель, построенную на основе RandomForestRegressor

Table 2 – Features contribution to the predicted regression model built on the basis of RandomForestRegressor

Порядковый номер столбца признака	Наименование признака	Вклад признака
3	Пищевой режим, К	0,315269
5	Пищевой режим, N	0,268636
4	Пищевой режим, Р	0,176935
1	Количество поливов	0,108139
0	Год использования травостоя	0,060828
2	Оросительная норма	0,056576
18	Мятлик луговой	0,006067
16	Овсяница тростниковая	0,001803
11	Вид посева: черезрядный	0,001767
10	Вид посева: смешанный	0,001763
17	Ежа сборная	0,001522
15	Кострец безостый	0,000696
7	Режим орошения, min	0,000000
8	Соотношение компонентов. Бобовые	0,000000
6	Режим орошения, max	0,000000
12	Люцерна желтогибридная	0,000000
13	Клевер белый	0,000000
14	Козлятник восточный	0,000000
9	Соотношение компонентов. Мятликовые	0,000000

Данные приведенной таблицы показывают, что наибольший вклад в модель вносят признаки, отражающие пищевой режим и режим орошения, это также соотносится с научными представлениями о важности факторов при формировании урожая сельскохозяйственных культур.

Выводы. В результате работы получены прогнозные регрессионные модели урожайности многолетних трав на основе моделей машинного обучения LinearRegression и RandomForestRegressor с коэффициентами детерминации соответственно 0,68 и 0,98, которые показывают, что значительная часть прогнозных данных объясняется построенной моделью. Вместе с тем необходимо отметить, что для обучения моделей были использованы относительно короткие ряды данных, т. е. возможно построение и более точных моделей при накоплении длинных рядов и расширении количества измеряемых в процессе получения урожая факторов. Числен-

ные значения вклада в модель таких признаков, как пищевой режим (0,176935–0,315269), а также соотношение числа поливов и оросительной нормы (0,056576–0,108139), подтверждают их значимость для условий территории проведения исследований, характеризующихся низким потенциальным плодородием и высокими значениями показателей засушливости климата, и подтверждают гипотезу о возможности построения прогнозной модели урожайности многолетних трав с использованием методов машинного обучения.

Список источников

1. Глобальный климат и почвенный покров России: проявления засухи, меры предупреждения, борьбы, ликвидация последствий и адаптационные мероприятия (сельское и лесное хозяйство): нац. докл. / Р. С. Х. Эдельгериев [и др.]. Т. 3. М.: Изд-во МБА, 2021. 700 с. DOI: 10.52479/978-5-6045103-9-1. EDN: MFABZG.
2. Овчинников А. С., Власов М. В., Куприянова С. В. Влияние мелиорации земель на минимизацию погодных флуктуаций и рост экономического эффекта сельскохозяйственного производства // Известия Нижневолжского агроуниверситетского комплекса: наука и высшее профессиональное образование. 2020. № 1(57). С. 14–23. DOI: 10.32786/2071-9485-2020-01-01. EDN: FENWMD.
3. Семененко С. Я. Некоторые аспекты необходимости разработки научно обоснованной зональной системы орошаемого земледелия // Орошаемое земледелие. 2021. № 4. С. 10–13. EDN: ISKBPI.
4. Галимов Р. Г. Основы алгоритмов машинного обучения – обучение с учителем // Аллея науки. 2017. Т. 1, № 14. С. 810–817. EDN: ZTBUCH.
5. Сохина С. А., Немченко С. А. Машинное обучение. Методы машинного обучения // Современная наука в условиях модернизационных процессов: проблемы, реалии, перспективы: сб. науч. ст. по материалам V Междунар. науч.-практ. конф., г. Уфа, 30 апр. 2021 г. Уфа: Вестник науки, 2021. С. 165–168. EDN: BKEJKE.
6. Mahajan J., Banal K., Mahajan S. Estimation of crop production using machine learning techniques: a case study of J&K // International Journal of Information Technology. 2021. Vol. 13, № 4. P. 1441–1448. <https://doi.org/10.1007/s41870-021-00653-7>.
7. Дронова Т. Н., Бурцева Н. И. Результаты исследований по полевому травосеянию на орошаемых землях Нижнего Поволжья // Проблемы развития АПК региона. 2019. № 4(40). С. 40–46. EDN: NHNBVP.
8. Продуктивность многолетних бобовых трав на орошении / Т. Н. Дронова, Н. И. Бурцева, Е. И. Молоканцева, И. П. Земцова, О. В. Головатюк // Известия Нижневолжского агроуниверситетского комплекса: наука и высшее профессиональное образование. 2022. № 2(66). С. 22–30. DOI: 10.32786/2071-9485-2022-02-02. EDN: QNKYKA.
9. Рогачев А. Ф., Мелихова Е. В., Плещенко Т. В. Нейросетевая система управления программируемым аграрным производством с использованием ретроспективных данных и результатов дистанционного зондирования: монография / Волгоградский ГАУ. Волгоград, 2021. 172 с. EDN: QBTBVB.
10. Использование методов машинного обучения для прогнозирования нитратного азота в почве / Т. А. Кизимова, В. С. Риксен, В. А. Шпак, К. Ю. Максимович, Р. Р. Галимов //

АгроЭкоИнфо [Электронный ресурс]. 2022. № 5(53). URL: https://agroecoinfo.ru/STATYI/2022/5/st_521.pdf (дата обращения: 15.03.2024). DOI: 10.51419/202125521. EDN: CKTGfH.

11. Определение вида заболеваний, поражающих листья картофеля, с использованием алгоритмов машинного обучения / А. Г. Возмилов, А. А. Лисов, В. Г. Урманов, Г. Н. Синева // Вестник НГИЭИ. 2023. № 3(142). С. 7–16. DOI: 10.24412/2227-9407-2023-3-7-16. EDN: BXWBRC.

12. Анчеков М. И., Боготова З. И. Применение методов искусственного интеллекта в селекции // Известия Кабардино-Балкарского научного центра РАН. 2020. № 6(98). С. 91–96. DOI: 10.35330/1991-6639-2020-6-98-91-96. EDN: EPNWWM.

13. Применение методов интеллектуального анализа данных при диагностировании качества семян пшеницы / Д. Д. Барышев, Н. Н. Барышева, Е. В. Авдеева, С. П. Пронин // Высокопроизводительные вычислительные системы и технологии. 2022. Т. 6, № 1. С. 114–118. EDN: OOHNCQI.

14. Поленов Д. Ю. Искусственный интеллект в регулировании продуктивности объектов сельского хозяйства // Вестник Воронежского государственного аграрного университета. 2021. Т. 14, № 1(68). С. 46–51. DOI: 10.53914/issn2071-2243_2021_1_46. EDN: XFNNWS.

References

1. Edelgeriev R.S.Kh. [et al.], 2021. *Global'nyy klimat i pochvennyy pokrov Rossii: proyavleniya zasukhi, mery preduprezhdeniya, bor'by, likvidatsiya posledstviy i adaptatsionnye meropriyatiya (sel'skoe i lesnoe khozyaystvo): nats. dokl.* [Global Climate and Soil Cover in Russia: Manifestations of Drought, Prevention Measures, Control, Elimination of Consequences and Adaptation Measures (Agriculture and Forestry). National report]. Vol. 3, Moscow, MBA Publ., 700 p., DOI: 10.52479/978-5-6045103-9-1, EDN: MFABZG. (In Russian).

2. Ovchinnikov A.S., Vlasov M.V., Kupriyanova S.V., 2020. *Vliyanie melioratsii zemel' na minimizatsiyu pogodnykh fluktuatsiy i rost ekonomicheskogo effekta sel'skokhozyaystvennogo proizvodstva* [Influence of land reclamation on minimizing weather fluctuations and increasing the economic effect of agricultural production]. *Izvestiya Nizhnevolzhskogo agrouniversitetskogo kompleksa: nauka i vysshee professional'noe obrazovanie* [Proceedings of the Lower Volga Agro-University Complex: Science and Higher Education], no. 1(57), pp. 14-23, DOI: 10.32786/2071-9485-2020-01-01, EDN: FENWMD. (In Russian).

3. Semenenko S.Ya., 2021. *Nekotorye aspekty neobkhodimosti razrabotki nauchno obosnovannoy zonal'noy sistemy oroshaemogo zemledeliya* [Some aspects of the need to develop a science-based zonal system of irrigated agriculture]. *Oroshaemoe zemledelie* [Irrigated Agriculture], no. 4, pp. 10-13, EDN: ICKBPJ. (In Russian).

4. Galimov R.G., 2017. *Osnovy algoritmov mashinnogo obucheniya – obuchenie s uchitelem* [Fundamental algorithms of machine learning – training with a teacher]. *Alleya nauki* [Alley of Science], vol. 1, no. 14, pp. 810-817, EDN: ZTBUCH. (In Russian).

5. Sokhina S.A., Nemchenko S.A., 2021. *Mashinnoe obuchenie. Metody mashinnogo obucheniya* [Machine learning. Machine learning methods]. *Sovremennaya nauka v usloviyakh modernizatsionnykh protsessov: problemy, realii, perspektivy: sb. nauchnykh statey po materialam V Mezhdunaridnoy nauchno-prakticheskoy konferentsii* [Modern Science in the Conditions of Modernization Processes: Problems, Realities, Prospects: Collection of Scientific Articles based on Proc. of the V International Scientific-Practical Conference]. Ufa, Bulletin of Science, pp. 165-168, EDN: BKEJFK. (In Russian).

6. Mahajan J., Banal K., Mahajan S., 2021. Estimation of crop production using machine learning techniques: a case study of J&K. *International Journal of Information Technology*, vol. 13, no. 4, pp. 1441-1448, <https://doi.org/10.1007/s41870-021-00653-7>.

7. Dronova T.N., Burtseva N.I., 2019. *Rezultaty issledovaniy po polevomu travoseyaniyu na oroshaemykh zemlyakh Nizhnego Povolzh'ya* [Research results on field fodder

grass cultivation on the irrigated lands of the Lower Volga region]. *Problemy razvitiya APK regiona* [Problems of Development of Agro-Industrial Complex of the Region], no. 4(40), pp. 40-46, EDN: NHNBPP. (In Russian).

8. Dronova T.N., Burtseva N.I., Molokantseva E.I., Zemtsova I.P., Golovatyuk O.V., 2022. *Produktivnost' mnogoletnikh bobovykh trav na oroshenii* [Productivity of perennial leguminous grasses under irrigation]. *Izvestiya Nizhnevolzhskogo agrouniversitetskogo kompleksa: nauka i vysshee professional'noe obrazovanie* [Proceedings of the Lower Volga Agro-University Complex: Science and Higher Education], no. 2(66), pp. 22-30, DOI: 10.32786/2071-9485-2022-02-02, EDN: QHKYKA. (In Russian).

9. Rogachev A.F., Melikhova E.V., Pleschenko T.V., 2021. *Neyrosetevaya sistema upravleniya programmiruemym agrarnym proizvodstvom s ispol'zovaniem retrospektivnykh dannykh i rezul'tatov distantsionnogo zondirovaniya: monografiya* [Neural Network Control System for Programmable Agricultural Production Using Retrospective Data and Remote Sensing Results: monograph]. Volgograd State Agrarian University, Volgograd, 172 p., EDN: QBTBVB. (In Russian).

10. Kizimova T.A., Riksen V.S., Shpak V.A., Maksimovich K.Yu., Galimov R.R., 2022. *Ispol'zovanie metodov mashinnogo obucheniya dlya prognozirovaniya nitratnogo azota v pochve* [Using machine learning techniques to predict nitrate nitrogen in soil]. *AgroEcoInfo*, no. 5(53), available: https://agroecoinfo.ru/STATYI/2022/5/st_521.pdf [accessed 15.03.2024], DOI: 10.51419/202125521, EDN: CKTGFH. (In Russian).

11. Vozmilov A.G., Lisov A.A., Urmanov V.G., Sineva G.N., 2023. *Opredelenie vida zabolevaniy, porazhayushchikh list'ya kartofelya, s ispol'zovaniem algoritmov mashinnogo obucheniya* [Determination of the type of potato leaves diseases with using machine learning]. *Vestnik NGIEI* [Bulletin NGIEI], no. 3(142), pp. 7-16, DOI: 10.24412/2227-9407-2023-3-7-16, EDN: BXWBRC. (In Russian).

12. Anchekov M.I., Bogotova Z.I., 2020. *Primenenie metodov iskusstvennogo intellekta v seleksii* [Artificial intelligence techniques in breeding]. *Izvestiya Kabardino-Balkarskogo nauchnogo tsentra RAN* [News of the Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences], no. 6(98), pp. 91-96, DOI: 10.35330/1991-6639-2020-6-98-91-96, EDN: EPNWWM. (In Russian).

13. Baryshev D.D., Barysheva N.N., Avdeeva E.V., Pronin S.P., 2022. *Primenenie metodov intellektual'nogo analiza dannykh pri diagnostirovanii kachestva semyan pshenitsy* [Application of machine learning methods in diagnosing wheat seed quality]. *Vysokoproizvoditel'nye vychislitel'nye sistemy i tekhnologii* [High-Performance Computing Systems and Technologies], vol. 6, no. 1, pp. 114-118, EDN: OOHCCI. (In Russian).

14. Polenov D.Yu., 2021. *Iskusstvennyy intellekt v regulirovanii produktivnosti ob"ektov sel'skogo khozyaystva* [Artificial intelligence in regulating the productivity of agricultural objects]. *Vestnik Voronezhskogo gosudarstvennogo agrarnogo universiteta* [Bull. of Voronezh State Agrarian University], vol. 14, no. 1(68), pp. 46-51, DOI: 10.53914/issn2071-2243_2021_1_46, EDN: XFNNWS. (In Russian).

Информация об авторах

С. С. Марченко – старший научный сотрудник, кандидат технических наук, Всероссийский научно-исследовательский институт орошаемого земледелия – филиал Федерального научного центра гидротехники и мелиорации имени А. Н. Костякова, Волгоград, Российская Федерация, marchenkosergey@mail.ru, ORCID ID: 0000-0002-2627-6465;
А. Е. Новиков – директор, доктор технических наук, член-корреспондент РАН, Всероссийский научно-исследовательский институт орошаемого земледелия – филиал Федерального научного центра гидротехники и мелиорации имени А. Н. Костякова, Волгоград, Российская Федерация, vnioz@yandex.ru, ORCID ID: 0000-0002-8051-4786;

Н. И. Бурцева – ведущий научный сотрудник, кандидат сельскохозяйственных наук, Всероссийский научно-исследовательский институт орошаемого земледелия – филиал Федерального научного центра гидротехники и мелиорации имени А. Н. Костякова, Волгоград, Российская Федерация, burtseva.ni58@yandex.ru, ORCID ID: 0000-0002-9787-7321;

С. Я. Семененко – главный научный сотрудник, доктор сельскохозяйственных наук, Всероссийский научно-исследовательский институт орошаемого земледелия – филиал Федерального научного центра гидротехники и мелиорации имени А. Н. Костякова, Волгоград, Российская Федерация, sergeysemenenko@list.ru, ORCID ID: 0000-0001-5992-8127.

Information about the authors

S. S. Marchenko – Senior Researcher, Candidate of Technical Sciences, All-Russian Research Institute of Irrigated Agriculture – branch of the Federal Scientific Center of Hydraulic Engineering and Land Reclamation named after A. N. Kostyakov, Volgograd, Russian Federation, marchenkosergey@mail.ru, ORCID ID: 0000-0002-2627-6465;

A. E. Novikov – Director, Doctor of Technical Sciences, Corresponding Member of the Russian Academy of Sciences, All-Russian Research Institute of Irrigated Agriculture – branch of the Federal Scientific Center of Hydraulic Engineering and Land Reclamation named after A. N. Kostyakov, Volgograd, Russian Federation, vnioz@yandex.ru, ORCID ID: 0000-0002-8051-4786;

N. I. Burtseva – Leading Researcher, Candidate of Agricultural Sciences, All-Russian Research Institute of Irrigated Agriculture – branch of the Federal Scientific Center of Hydraulic Engineering and Land Reclamation named after A. N. Kostyakov, Volgograd, Russian Federation, burtseva.ni58@yandex.ru, ORCID ID: 0000-0002-9787-7321;

S. Ya. Semenenko – Chief Researcher, Doctor of Agricultural Sciences, All-Russian Research Institute of Irrigated Agriculture – branch of the Federal Scientific Center of Hydraulic Engineering and Land Reclamation named after A. N. Kostyakov, Volgograd, Russian Federation, sergeysemenenko@list.ru, ORCID ID: 0000-0001-5992-8127.

Вклад авторов: все авторы настоящего исследования принимали непосредственное участие в сборе и подготовке материала, проведении расчетов и анализе результатов данного исследования. Все авторы настоящей статьи ознакомились с представленным окончательным вариантом и одобрили его.

Все авторы в равной степени несут ответственность за нарушения в сфере этики научных публикаций.

Contribution of the authors: all authors of this study were directly involved in data collection and preparation, computational analysis and outcome analysis of this study. All authors of this article have reviewed and approved the final version submitted.

All authors are equally responsible for ethical violations in scientific publications.

Авторы заявляют об отсутствии конфликта интересов.

The authors declare no conflicts of interests.

Статья поступила в редакцию 20.02.2024; одобрена после рецензирования 22.04.2024; принята к публикации 23.04.2024.

The article was submitted 20.02.2024; approved after reviewing 22.04.2024; accepted for publication 23.04.2024.