

СОВРЕМЕННЫЕ ПРОБЛЕМЫ МЕЛИОРАТИВНО- ВОДОХОЗЯЙСТВЕННОГО КОМПЛЕКСА И ПУТИ ИХ РЕШЕНИЯ

Научная статья
УДК 631.559.004

Прогнозирование урожайности зерновых культур на основе метеорологических данных с применением машинного обучения

Никита Михайлович Почёмин¹, Геннадий Геннадьевич Морковкин²

^{1, 2}Государственный университет по землеустройству, Москва, Российская Федерация

¹pochyomin@list.ru, <https://orcid.org/0000-0002-5899-5464>

²ggmork@mail.ru, <https://orcid.org/0000-0001-8830-7135>

Аннотация. Цель: разработка научно обоснованной методики прогнозирования урожайности зерновых культур на основе интеграции данных высокочастотного мониторинга с передовыми методами машинного обучения для последующей оптимизации режимов орошения. **Материалы и методы.** Исследование выполнено на основе массива данных, полученных с сети из 38 автоматических метеостанций, расположенных в Алтайском крае и функционировавших в течение вегетационного периода 2024 г. Были собраны и обработаны почасовые данные по 29 метеорологическим параметрам. Для построения прогностических моделей применялся комплекс ансамблевых алгоритмов, включая Random Forest, Gradient Boosting и XGBoost, в сравнении с классическими линейными моделями. Для интерпретации результатов и выявления значимости предикторов использовался метод SHAP-анализа (SHapley Additive exPlanations). **Результаты.** Установлено, что наилучшую прогностическую способность продемонстрировала модель Random Forest ($R^2 = 0,012$, RMSE = 14,10 ц/га). SHAP-анализ выявил нелинейный характер влияния метеофакторов. Ключевым предиктором урожайности является максимальная температура воздуха в июле. Определен пороговый эффект: при превышении максимальной температуры в июле (+34 °C) урожайность статистически значимо снижалась. Вторым по значимости фактором оказалось количество осадков в сентябре. **Выводы.** Доказана эффективность применения методов машинного обучения и SHAP-анализа для выявления критических метеорологических порогов, влияющих на продуктивность зерновых культур в условиях орошения. Полученные результаты позволяют рекомендовать внедрение систем высокочастотного мониторинга и прогнозных моделей для оперативной корректировки режимов орошения, что способствует смягчению последствий температурного стресса и повышению эффективности водопользования в земледелии.

Ключевые слова: машинное обучение, прогнозирование урожайности, орошаемое земледелие, Random Forest, SHAP-анализ, метеорологические параметры, температурный стресс, эффективность мелиорации

Апробация результатов исследования: основные положения статьи доложены на Всероссийской научно-практической конференции «Современные проблемы мелиоративно-водохозяйственного комплекса и пути их решения» (г. Новочеркасск, 10 октября 2025 г.).

Для цитирования: Почёмин Н. М., Морковкин Г. Г. Прогнозирование урожайности зерновых культур на основе метеорологических данных с применением машинного обучения // Пути повышения эффективности орошаемого земледелия. 2025. Т. 97, № 3. С. 187–202.

MODERN PROBLEMS OF LAND RECLAMATION AND WATER INDUSTRIAL COMPLEX AND WAYS TO SOLVE THEM

Original article

Machine learning-based crop yield prediction using meteorological data



Nikita M. Pochemin¹, Gennady G. Morkovkin²

^{1, 2}State University of Land Use Planning, Moscow, Russian Federation

¹pochyomin@list.ru, <https://orcid.org/0000-0002-5899-5464>

²ggmork@mail.ru, <https://orcid.org/0000-0001-8830-7135>

Abstract. Purpose: to develop a scientifically based methodology for grain crop yields forecasting by integrating high-frequency monitoring data with advanced machine learning methods for subsequent optimization of irrigation regimes. **Materials and methods.** The study was conducted on the data array obtained from a network of 38 automatic weather stations located in the Altai Territory and functioning during the 2024 growing season. Hourly data on 29 meteorological indicators were collected and processed. To build predictive models, a set of ensemble algorithms including Random Forest, Gradient Boosting, and XGBoost, in comparison with classical linear models was used. SHAP analysis (SHapley Additive exPlanations) was used to interpret the results and identify the significance of predictors. **Results.** It was stated that Random Forest model demonstrated the best predictive ability ($R^2 = 0.012$, RMSE = 14.10 c/ha). SHAP analysis revealed a nonlinear influence of meteorological factors. The key yield predictor is the maximum air temperature in July. A threshold effect was determined: when the maximum temperature in July (+34 °C) was exceeded, yield decreased statistically significantly. The second most significant factor was the amount of precipitation in September. **Conclusions.** The effectiveness of machine learning and SHAP analysis in identifying critical meteorological thresholds affecting the grain crop productivity under irrigated conditions has been proven. The obtained results allow to recommend the implementation of high-frequency monitoring systems and predictive models for prompt adjustment of irrigation regimes, that helps mitigate the effects of temperature stress and improve the efficiency of water use in agriculture.

Keywords: machine learning, yield forecasting, irrigated agriculture, Random Forest, SHAP analysis, meteorological parameters, temperature stress, land reclamation efficiency

Evaluation of the research results: the main provisions of the article were reported at the All-Russian scientific and practical conference “Modern problems of land reclamation and water industrial complex and ways to solve them” (Novocherkassk, October 10, 2025).

For citation: Pochemin N. M., Morkovkin G. G. Machine learning-based crop yield prediction using meteorological data. *Ways of Increasing the Efficiency of Irrigated Agriculture*. 2025;97(3):187–202. (In Russ.).

Введение. Сельское хозяйство является одной из наиболее зависимых от погодно-климатических условий отраслей экономики. Интенсификация производства и учащение экстремальных погодных явлений, связанных с глобальным изменением климата, диктуют необходимость перехода к прецизионным, data-driven подходам в управлении агропредприятиями. Прогнозирование урожайности традиционно основывалось на регрессионных моделях [1, 2] и эмпирических зависимостях, которые зачастую не учитывают комплексного взаимодействия множества факторов в разные фенологические фазы развития растений.

Развитие технологий точного земледелия, в частности распростране-

ние сетей автоматических метеостанций, позволяет собирать высокочастотные данные по широкому спектру параметров (температура, влажность, солнечная радиация, скорость ветра и др.). Однако объем и многомерность таких данных требуют применения более совершенных аналитических инструментов.

Методы машинного обучения (МО), в частности ансамблевые алгоритмы, такие, как Random Forest и градиентный бустинг, демонстрируют высокую эффективность в задачах регрессии и классификации с нелинейными зависимостями и взаимодействиями признаков [3–7]. Основным вызовом при использовании черных ящиков МО является интерпретируемость результатов. Решением этой проблемы стали методы объяснимого искусственного интеллекта (XAI), среди которых SHAP-анализ занял лидирующие позиции благодаря своей теоретической обоснованности [8, 9]. SHAP позволяет количественно оценить вклад каждого признака в итоговое предсказание модели для каждого отдельного наблюдения и в среднем по выборке.

Цель данного исследования – разработка научно обоснованной методики прогнозирования урожайности зерновых культур на основе интеграции данных высокочастотного мониторинга с передовыми методами машинного обучения для последующей оптимизации режимов орошения.

Материалы и методы. Исследование проводилось на основе данных, собранных с 38 автоматических метеостанций, расположенных в зонах товарного производства зерновых культур. Данные собирались в течение вегетационного периода 2024 г. с почасовым разрешением. Для каждого месяца (с апреля по октябрь, префиксы m4–m10) агрегировали показатели статистики (мин., макс., среднее, медиана, стандартное отклонение, квантили и др.) по следующим группам параметров: ультразвуковой анемометр направление [градус], порыв ветра [m/s], ультразвуковой анемометр скорость [m/s], влажность листа [минимум], дефицит давления насыщенных паров (VPD) [kPa], дельта T [°C], точка росы [°C], PI54D проника-

емость, PI54D [%] (объемная влажность почвы), PI54D температура [°C], относительная влажность [%] (воздуха), температура воздуха, высокая точность [°C], осадки [mm], солнечная радиация [W/m²].

Целевой переменной выступала фактическая урожайность пшеницы (ц/га) на полях, соответствующих зонам влияния автоматических метеостанций METOS программы КлиматиПоле. Перед обучением моделей был проведен этап предобработки: удаление признаков с высокой корреляцией, импутация пропущенных значений медианами и стандартизация данных для линейных моделей.

Для построения моделей прогнозирования урожайности были испытаны следующие алгоритмы:

- 1) Random Forest (RF) – ансамбль решающих деревьев, устойчивый к шуму и переобучению;
- 2) Gradient Boosting (GB) – ансамбль, последовательно улучшающий предсказания за счет компенсации ошибок предыдущих деревьев;
- 3) XGBoost (XGB) – эффективная реализация градиентного бустинга с регуляризацией [10];
- 4) Ridge Regression – линейная модель с L2-регуляризацией;
- 5) Lasso Regression – линейная модель с L1-регуляризацией, способная обнулять веса незначимых признаков;
- 6) Support Vector Regression (SVR) – метод опорных векторов для задач регрессии [11].

Выбор гиперпараметров моделей проводился с помощью перекрестной проверки (GridSearchCV или RandomizedSearchCV). Датасет был разделен на обучающую и тестовую выборки в соотношении 75/25 %, всего в датасет вошли 133461 строка данных и 385 первичных факторов. Качество моделей оценивалось по коэффициенту детерминации (R^2) и среднеквадратической ошибке (RMSE) [12].

Для интерпретации решений лучшей модели использовался SHAP-анализ на основе TreeExplainer. Рассчитывались значения SHAP для каждого наблюдения в тестовой выборке. Для визуализации результатов применялись:

- Summary plot (bar) – усредненная по модулю важность признаков для всей модели;
- Summary plot (dot) – детальная визуализация, показывающая распределение влияния признака (значение SHAP) в зависимости от величины самого признака и его воздействия на прогноз.

Результаты и обсуждение. Результаты валидации моделей на тестовой выборке представлены в таблице 1.

Таблица 1 – Сравнение производительности моделей машинного обучения

Table 1 – Comparison of machine learning model performance

Модель	R^2 (Test)	RMSE (Test, ц/га)
Random Forest	0,012	14,10
Gradient Boosting	–0,024	14,35
XGBoost	–0,085	14,77
Ridge Regression	–0,002	14,19
Lasso Regression	–0,796	19,01
ElasticNet	–0,448	17,07
SVR	–0,027	14,37

Как видно из таблицы 1, модель Random Forest показала наилучший, хотя и близкий к нулю, результат ($R^2 = 0,012$). Отрицательные значения R^2 у других моделей указывают на то, что их предсказания хуже, чем простое среднее значение по выборке. Это свидетельствует о чрезвычайно сложной природе данных и наличии сильных нелинейностей, которые не могут быть адекватно описаны линейными моделями и некоторыми сложными ансамблями без тщательной настройки [13]. Низкое значение R^2 у лучшей модели также может объясняться тем, что в данных присутствуют значительные шумы или неучтенные факторы (например, агротехнические, поч-

венные, фитосанитарные). Однако, как показал дальнейший анализ, даже такая модель содержит ценную информацию о взаимосвязях.

SHAP-анализ модели Random Forest позволил идентифицировать топ-20 наиболее влиятельных признаков. На рисунке 1 представлен усредненный bar-plot важности климатических переменных.




Рисунок 1 – SHAP summary plot (bar) значимости климатических признаков по отношению к урожайности

Figure 1 – SHAP summary plot (bar) of the climate indicator significance in relation to crop yield

Наиболее значимым предиктором урожайности оказался признак «m7_Температура воздуха, высокая точность _°C_max» (максимальная температура в июле). Вторым по важности стал «m9_Осадки_min_total» (минимальное общее количество осадков в сентябре), что сходится с результатами похожих исследований [14]. В первую десятку также вошли параметры солнечной радиации, скорости ветра, точки росы и VPD в июле.

Более детальная картина взаимодействия признаков и целевой переменной представлена на dot-plot (рисунок 2).

Анализ рисунка 2 для ключевого признака «m7_Температура воздуха_max» выявил четкий нелинейный характер его влияния.




Рисунок 2 – SHAP summary plot (dot) значимости климатических признаков по отношению к урожайности с вектором влияния

Figure 2 – SHAP summary plot (dot) of the climate indicator significance in relation to crop yield with an influence vector

Низкие и средние значения признака (синие точки, примерно до +34 °C) соответствуют отрицательным значениям SHAP. Это означает, что такие температуры оказывают негативное влияние на предсказанную моделью урожайность, т. е. в контексте других факторов они ассоциированы с более низким урожаем.

Высокие значения признака (красные точки, выше +34 °C) соответствуют положительным значениям SHAP. Это указывает на то, что экстремально высокие температуры июля вносят положительный вклад в пред-

сказание, что противоречит общепринятой агрономической логике. Данный артефакт требует дальнейшего исследования.

Для верификации этого результата был проведен дополнительный анализ сырых данных. Была обнаружена следующая эмпирическая зависимость:

- в хозяйствах, где максимальная температура июля не превышала +34 °С, урожайность составляла в среднем более 40 ц/га (от 40 до 55 ц/га);
- в хозяйствах, где максимальная температура июля превышала +34 °С, урожайность статистически значимо снижалась до менее 40 ц/га.

Этот вывод подтверждает пороговый эффект влияния жары в критическую фазу развития зерновых (фаза налива зерна в июле) и демонстрирует, что SHAP-анализ способен выявлять такие сложные, нелинейные пороговые зависимости, которые неочевидны при традиционном анализе.

Для лучшего понимания логики модели была визуализирована структура одного из решающих деревьев ансамбля Random Forest (рисунок 3). Верхний узел дерева принимает решение на основе признака «m7_Дельта T _°C__max» с порогом 10,5 °С, что подтверждает важность термических параметров июля.

Полученные результаты имеют важное теоретическое и практическое значение для цифровизации сельского хозяйства и адаптации мелиоративных мероприятий. Ансамбли деревьев решений эффективно работают с табличными данными, содержащими нелинейные зависимости [3–6, 9]. Во многих отечественных и зарубежных работах значимый вклад имеет включение в модель почвенных характеристик и условий ведения хозяйства [15–20], опора на пространственное моделирование по мультиспектральным данным ДЗЗ [6, 16, 21–22]. Однако включение этих факторов снизит интерпретируемость модели. Возможно, стоит рассмотреть разработку системы моделирования отдельных групп факторов и объединения моделей этих групп в ансамбль.




Рисунок 3 – Визуализация решающего дерева из ансамбля RF
 Figure 3 – Visualization of the decision tree from the RF ensemble

Выводы

1 Преимущество ансамблевых методов. Несмотря на скромные метрики предсказания, модель Random Forest оказалась наиболее устойчивой к сложностям данных.

2 Критическая роль температурного режима июля. Выявленное доминирование максимальных температур июля полностью соответствует агрономическим знаниям. Июль для зерновых культур в условиях умеренного климата – это ключевая фаза налива и созревания зерна. Экстремальная жара (+34 °C и выше) в этот период вызывает тепловой стресс, ускоряет фазы развития, приводит к запалу зерна и значительной потере урожая. SHAP-анализ не только подтвердил этот известный факт, но и количественно оценил пороговое значение.

3 Значение осадков сентября. Высокая важность осадков в сентябре может быть связана с их ролью в накоплении продуктивной влаги в почве перед севом озимых культур или в создании благоприятных условий для всходов. Это указывает на необходимость учета метеоусловий не только в период вегетации, но и в межсезонье.

4 Интерпретация сложных взаимосвязей. SHAP-анализ показал смешанное влияние таких факторов, как скорость ветра и дельта температуры. Например, влияние скорости ветра может быть двояким: умеренный ветер способствует опылению и проветриванию, снижая влажность, а сильные порывы могут вызывать полегание посевов. Это подчеркивает необходимость учета контекста и взаимодействия факторов.

5 Ограничения исследования. Основным ограничением является лишь один известный год урожайности и отсутствие в модели неметеорологических факторов (тип почвы, агротехника, сорт, уровень внесения удобрений и СЗР), которые вносят значительный вклад в урожайность. Низкий R^2 модели указывает на то, что метеоданные сами по себе недостаточны для точного прогноза, но достаточны для выявления критических стрессовых факторов.

Практические рекомендации. Внедрение систем мониторинга с акцентом на отслеживание экстремальных температур в июле. При прогнозировании превышения порога +34 °С следует планировать мероприятия по смягчению стресса (например, внекорневые подкормки, полив при наличии возможности).

В рамках данного исследования была успешно продемонстрирована методология применения машинного обучения и SHAP-анализа для моделирования урожайности на основе метеорологических данных. Установлено, что:

1) модель Random Forest, несмотря на низкий общий показатель точности ($R^2 = 0,012$), оказалась способна выявлять статистически значимые и агрономически интерпретируемые зависимости;

2) с помощью SHAP-анализа выявлен ключевой метеофактор – максимальная температура воздуха в июле – и определен его критический порог (+34 °С), превышение которого ведет к значительному снижению урожайности с 55 до 15 ц/га;

3) подтверждена высокая ценность высокочастотного мониторинга метеопараметров не только в текущем вегетационном сезоне, но и в предшествующие периоды.

Перспективы дальнейших исследований видятся в интеграции мультимодальных данных (спутниковые снимки, данные с датчиков на технике, почвенные карты) в единую модель, а также в использовании более сложных архитектур машинного обучения, таких, как рекуррентные нейронные сети (RNN), для учета временных рядов метеоданных.

Список источников

1. Математическая модель для прогнозирования урожайности яблони на подвое 62-396 / В. Л. Захаров, С. С. Бунеев, С. Ю. Шубкин, Б. А. Сотников, В. А. Кравченко // Вестник российской сельскохозяйственной науки. 2024. № 4. С. 69–71. DOI: 10.31857/S2500208224040126. EDN: XKVIHS.

2. Агрометеорологические условия и прогнозирование урожайности зерновых и зернобобовых культур в субъектах восточной части Сибирского федерального округа /

Пути повышения эффективности орошаемого земледелия. 2025. Т. 97, № 3. С. 187–202.
Ways of Increasing the Efficiency of Irrigated Agriculture. 2025. Vol. 97, no. 3. P. 187–202.

А. И. Страшная, А. В. Павлова, Т. В. Кулакова, П. С. Кланг // Гидрометеорологические исследования и прогнозы. 2023. № 4(390), С. 118–137. DOI: 10.37162/2618-9631-2023-4-118-137. EDN: GLLOLU.

3. Padma T., Sinha D. Crop Yield Prediction Using Improved Random Forest // ITM Web of Conferences. 2023. Vol. 56. P. 02007. DOI: 10.1051/itmconf/20235602007. EDN: ZULROF.

4. Crop Yield Forecasting with Precise Machine Learning / S. K. Verma, S. Sinha, P. K. Deb Chaudhury [et al.] // International Conference on Innovative Computing and Communications: Proceedings of ICICC 2023, Vol. 3. Lecture Notes on Networks and Systems, Vol. 537. Singapore: Springer, P. 445–453. DOI: 10.1007/978-981-99-3010-4_38.

5. Reddy S. M., Naini S., Thatipamula S. An Optimized Machine Learning Approach for Predicting Various Crop Yields // SSRN Electronic Journal. 2021. DOI: 10.2139/ssrn.3808343.

6. Wheat Yield Prediction Using Machine Learning: A Survey / T. G. Debelee, S. R. Kebede, F. G. Waldamichael, D. M. Tadesse // Pan African Conference on Artificial Intelligence: Communications in Computer and Information Science. Vol. 1800. 2023. P. 114–132. DOI: 10.1007/978-3-031-31327-1_7.

7. An Ensemble Algorithm for Crop Yield Prediction / M. Keerthana, K. J. M. Meghana, S. Pravallika [et al.] // Proceedings of the 2021 5th International Conference on Trends in Electronics and Informatics (ICOEI). 2021. P. 1547–1552. DOI: 10.1109/ICICV50876.2021.9388479.

8. Tan J. A. Comparative Analysis of the Machine Learning Model for Crop Yield Prediction in Quezon Province, Philippines // Proceedings of the 2023 8th International Conference on Communication Systems and Network Technologies (CSNT). 2023. P. 1–5. DOI: 10.1109/CSNT57126.2023.10134593.

9. Machine Learning-Based Crop Yield Prediction in South India: Performance Analysis of Various Models / U. V. Nikhil, A. M. Pandiyan, S. P. Raja, Z. Stamenkovic // Computers. 2024. Vol. 13. № 6. P. 137. DOI: 10.3390/computers13060137. EDN: GFHVUA.

10. Интерпретируемая модель машинного обучения для прогнозирования урожайности яровой пшеницы / В. К. Каличкин, В. И. Усенко, А. А. Гаркуша, Д. С. Федоров, К. Ю. Максимович // Российская сельскохозяйственная наука. 2025, № 2. С. 59–66. DOI: 10.31857/S2500262725020117. EDN: DFJMTX.

11. Файзуллин Р. В., Новикова О. А. Применение методов машинного обучения для прогнозирования в сельскохозяйственном секторе экономики // Интеллектуальные системы в производстве. 2024, № 22(2), С. 69–79. DOI: 10.22213/2410-9304-2024-2-69-79. EDN: SBLSEG.

12. L. B. Rananavare, S. Chitnis, Crop Yield Prediction Using Temporal Data // IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT) 2022. Bangalore, India, 2022. P. 1–5, DOI: 10.1109/CONECCT55679.2022.9865791.

13. A. Raddekar, D. Chikmurge, M. Subhedar. Prediction of Crop Yield with Feature Dimension Reduction Method Using Regression Models // 7th International Conference On Computing: Communication, Control And Automation (ICCUBEA) 2023. Pune, India, 2023. pp. 1–6. DOI: 10.1109/ICCUBEA58933.2023.10392189.

14. Машинное обучение в качестве инструмента прогнозирования урожайности сельскохозяйственных культур / П. К. Куценогий, В. К. Каличкин, А. Л. Пакуль, С. П. Куценогий // Российская сельскохозяйственная наука. 2021, № 1. С. 72–75. DOI: 10.31857/S2500262721010178. EDN: GINGAQ.

15. Crop recommendation and yield prediction using machine learning algorithms / V. Sundari, M. Anusree, U. Swetha, R. Divya Lakshmi // World Journal of Advanced Research and Reviews. 2022. Vol. 14, №. 3. P. 452–459. DOI: 10.30574/wjarr.2022.14.3.0581. EDN: TVJSDU.

16. Rastog R., Bhardwaj M. K., Sharma A. Crop and Yield Prediction Through Machine Learning Techniques to Maximize Production: 21st Century Sustainable Approach for Smart Cities 5.0 // Proceedings 4th International Conference on Advances in Computing, Communication Control and Networking (ICAC3N). Greater Noida, India, 2022. P. 1286–1291. DOI: 10.1109/ICAC3N56670.2022.10074244.

17. Crop Yield Prediction Techniques Using Machine Learning Algorithms / M. Gupta, B. V. Santhosh Krishna, B. Kavyashree, H. R. Narapureddy, N. Surapaneni, K. Varma // 8th International Conference on Smart Structures and Systems (ICSSS) 2022. Chennai, India, 2022. P. 1–7, DOI: 10.1109/ICSSS54381.2022.9782246.

18. Agriculture Crop Selection and Yield Prediction using Machine Learning Algorithms / M. Aruna Devi, D. Suresh, D. Jeyakumar, D. Swamydoss and M. Lilly Florence // Second International Conference on Artificial Intelligence and Smart Energy (ICAIS) 2022. Coimbatore, India, 2022. P. 510–517. DOI: 10.1109/ICAIS53314.2022.9742846.

19. Toomula S., Pelluri S. Design of Kernel Extreme Learning Machine based Intelligent Crop Yield Prediction Model // International Conference on Automation, Computing and Renewable Systems (ICACRS) 2022. Pudukkottai, India, 2022. P. 694–701. DOI: 10.1109/ICACRS55517.2022.10029093.

20. Machine Learning Algorithms for Crop Yield Prediction in Real-Time Scenarios / N. V. S. Krishna, P. Neeraj, B. Surya, B. V. Prudhvi and V. H. Deepthi // 4th International Conference on Signal Processing and Communication (ICSPC) 2023. Coimbatore, India, 2023. P. 377–381. DOI: 10.1109/ICSPC57692.2023.10126011.

21. Архипова М. Ю. Моделирование урожайности зерновых культур сельскохозяйственных регионов с использованием технологий компьютерного зрения // Экономика региона. 2022. Т. 18, № 2. С. 581–594. DOI: 10.17059/ekon.reg.2022-2-20. EDN: HWJDJG.

22. Морковкин Г. Г., Шаповалов Д. А., Максимова Н. Б. Разработка методики оценки состояния плодородия земель на основе моделирования урожайности сельскохозяйственных культур по природным зонам Алтайского края // Международный сельскохозяйственный журнал. 2025. Т. 68, № 4(406). С. 433–437. DOI: 10.55486/25876740_2025_68_4_433.

References

1. Zakharov V.L., Buneev S.S., Shubkin S.Yu., Sotnikov B.A., Kravchenko V.A., 2024. *Matematicheskaya model' dlya prognozirovaniya urozhaynosti yabloni na podvoe* 62-396 [Mathematical model for predicting the yield of apple trees on rootstock 62-396]. *Vestnik Rossiyskoy sel'skokhozyaystvennoy nauki* [Bulet. of Russian Agricultural Science], no. 4, pp. 69-71, DOI: 10.31857/S2500208224040126, EDN: XKVIHS. (In Russian).

2. Strashnaya A.I., Pavlova A.V., Kulakova T.V., Klang P.S., 2023. *Agrometeorologicheskie usloviya i prognozirovaniye urozhaynosti zernovykh i zernobobovykh kul'tur v sub"ektakh vostochnoy chasti Sibirskogo federal'nogo okruga* [Agrometeorological conditions and prediction of the yield of grain and leguminous crops in the constituent entities of the eastern Siberian Federal District]. *Gidrometeorologicheskie issledovaniya i prognozy* [Hydrometeorological Research and Forecasting], no. 4(390), pp. 118-137, DOI: 10.37162/2618-9631-2023-4-118-137, EDN: GLOLLU. (In Russian).

3. Padma T., Sinha D., 2023. Crop Yield Prediction Using Improved Random Forest. *ITM Web of Conferences*. vol. 56, pp. 02007. DOI: 10.1051/itmconf/20235602007. EDN: ZULROF.

4. Verma S.K., Sinha S., Deb Chaudhury P.K., [et al.]. 2023. Crop Yield Forecasting with Precise Machine Learning. *International Conference on Innovative Computing and Communications: Proceedings of ICICC*, vol. 3. Lecture Notes on Networks and Systems, vol. 537. Singapore, Springer, pp. 445-453. DOI: 10.1007/978-981-99-3010-4_38.

5. Reddy S.M., Naini S., Thatipamula S., 2021. An Optimized Machine Learning Approach for Predicting Various Crop Yields. SSRN Electronic Journal, DOI: 10.2139/ssrn.3808343.
6. Debelee T.G., Kebede S.R., Waldamichael F.G., Tadesse D.M., 2023. Wheat Yield Prediction Using Machine Learning: A Survey. Pan African Conference on Artificial Intelligence: Communications in Computer and Information Science, vol. 1800, pp. 114-132, DOI: 10.1007/978-3-031-31327-1_7.
7. Keerthana M., Meghana K. J. M., Pravallika S. [et al.], 2021. An Ensemble Algorithm for Crop Yield Prediction. Proceedings of the 2021 5th International Conference on Trends in Electronics and Informatics (ICOEI), pp. 1547-1552, DOI: 10.1109/ICICV50876.2021.9388479.
8. Tan J.A., 2023. Comparative Analysis of the Machine Learning Model for Crop Yield Prediction in Quezon Province, Philippines. Proceedings of the 2023 8th International Conference on Communication Systems and Network Technologies (CSNT), pp. 1-5, DOI: 10.1109/CSNT57126.2023.10134593.
9. Nikhil U.V., Pandiyan A.M., Raja S.P., Stamenkovic Z., 2024. Machine Learning-Based Crop Yield Prediction in South India: Performance Analysis of Various Models. Computers, vol. 13, no. 6, p. 137, DOI: 10.3390/computers13060137, EDN: GFHVUA.
10. Kalichkin V.K., Usenko V.I., Garkusha A.A., Fedorov D.S., Maksimovich K.Yu., 2025. *Interpretiruemaya model' mashinnogo obucheniya dlya prognozirovaniya urozhaynosti yarovoy pshenitsy* [An interpretable machine learning model for spring wheat yield forecasting]. *Rossiyskaya sel'skokhozyaystvennaya nauka* [Russian Agricultural Science], no. 2, pp. 59-66, DOI: 10.31857/S2500262725020117, EDN: DFJMTX. (In Russian).
11. Fayzullin R.V., Novikova O.A., 2024. *Primenenie metodov mashinnogo obucheniya dlya prognozirovaniya v sel'skokhozyaystvennom sektore ekonomiki* [Application of machine learning methods for forecasting in the agricultural sector of the economy]. *Intellektual'nye sistemy v proizvodstve* [Intelligent Systems in Manufacturing], no. 22(2), pp. 69-79, DOI: 10.22213/2410-9304-2024-2-69-79, EDN: SBLSEG. (In Russian).
12. Rananavare L.B., Chitnis S., 2022. Crop Yield Prediction Using Temporal Data. IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT). Bangalore, India, pp. 1-5, DOI: 10.1109/CONECCT55679.2022.9865791.
13. Raddekar A., Chikmurge D., Subhedar M., 2023. Prediction of Crop Yield with Feature Dimension Reduction Method Using Regression Models. The 7th International Conference On Computing: Communication, Control and Automation (ICCUBEA) Pune, India, pp. 1-6, DOI: 10.1109/ICCUBEA58933.2023.10392189.
14. Kutsenogii P.K., Kalichkin V.K., Pakul A.L., Kutsenogii S.P., 2021. *Mashinnoe obuchenie v kachestve instrumenta prognozirovaniya urozhaynosti sel'skokhozyaystvennykh kul'tur* [Machine learning as a tool for crop yields forecast]. *Rossiyskaya sel'skokhozyaystvennaya nauka* [Russian Agricultural Science], no. 1, pp. 72-75, DOI: 10.31857/S2500262721010178, EDN: GINGAQ. (In Russian).
15. Sundari V., Anusree M., Swetha U., Divya Lakshmi R., 2022. Crop recommendation and yield prediction using machine learning algorithms. World Journal of Advanced Research and Reviews. vol. 14, no. 3, pp. 452-459, DOI: 10.30574/wjarr.2022.14.3.0581, EDN: TVJSDU.
16. Rastog R., Bhardwaj M.K., Sharma A., 2022. Crop and Yield Prediction Through Machine Learning Techniques to Maximize Production: 21st Century Sustainable Approach for Smart Cities 5.0. Proceed. 4th International Conference on Advances in Computing, Communication Control and Networking (ICAC3N). Greater Noida, India, pp. 1286-1291, DOI: 10.1109/ICAC3N56670.2022.10074244.
17. Gupta M., Santhosh Krishna B.V., Kavyashree B., Narapureddy H.R., Surapaneni N., Varma K., 2022. Crop Yield Prediction Techniques Using Machine Learning Algorithms.

Пути повышения эффективности орошаемого земледелия. 2025. Т. 97, № 3. С. 187–202.
Ways of Increasing the Efficiency of Irrigated Agriculture. 2025. Vol. 97, no. 3. P. 187–202.

International Conference on Smart Structures and Systems (ICSSS) Chennai. India, pp. 1-7, DOI: 10.1109/ICSSS54381.2022.9782246.

18. Aruna Devi M., Suresh D., Jeyakumar D., Swamydoss D., Lilly Florence M., 2022. Agriculture Crop Selection and Yield Prediction using Machine Learning Algorithms. Second International Conference on Artificial Intelligence and Smart Energy (ICAIS) Coimbatore. India, pp. 510-517, DOI: 10.1109/ICAIS53314.2022.9742846.

19. Toomula S., Pelluri S., 2022. Design of Kernel Extreme Learning Machine based Intelligent Crop Yield Prediction Model. International Conference on Automation, Computing and Renewable Systems (ICACRS). Pudukkottai. India, pp. 694-701, DOI: 10.1109/ICACRS55517.2022.10029093.

20. Krishna N.V.S., Neeraj P., Surya B., Prudhvi B.V., Deepthi V.H., 2023. Machine Learning Algorithms for Crop Yield Prediction in Real-Time Scenarios. 4th International Conference on Signal Processing and Communication (ICSPC) Coimbatore. India, pp. 377-381, DOI: 10.1109/ICSPC57692.2023.10126011.

21. Arkhipova M.Yu., 2022. *Modelirovanie urozhaynosti zernovykh kul'tur sel'skokhozyaystvennykh regionov s ispol'zovaniem tekhnologiy komp'yuternogo zreniya* [Modelling crop yield in agricultural regions using computer vision technologies]. *Ekonomika regiona* [Economy of Regions], vol. 18, no. 2, pp. 581-594, DOI: 10.17059/ekon.reg.2022-2-20, EDN: HWJDJG. (In Russian).

22. Morkovkin G.G., Shapovalov D.A., Maksimova N.B., 2025. *Razrabotka metodiki otsenki sostoyaniya plodorodiya zemel' na osnove modelirovaniya urozhaynosti sel'skokhozyaystvennykh kul'tur po prirodnym zonam Altayskogo kraya* [Development of a methodology for assessing the state of Altai Territory]. *Mezhdunarodnyy sel'skokhozyaystvennyy zhurnal* [International Agricultural Journal], vol. 68, no. 4(406), pp. 433-437, DOI: 10.55486/25876740_2025_68_4_433. (In Russian).

Информация об авторах

Н. М. Почёмин – аспирант кафедры почвоведения, мелиорации и геоэкологии, Государственный университет по землеустройству, Москва, Российская Федерация, rochyomin@list.ru, ORCID ID: 0000-0002-5899-5464;

Г. Г. Морковкин – профессор кафедры почвоведения, мелиорации и геоэкологии, доктор сельскохозяйственных наук, профессор, Государственный университет по землеустройству, Москва, Российская Федерация, ggmark@mail.ru, ORCID ID: 0000-0001-8830-7135.

Information about the authors

N. M. Pochemin – Postgraduate Student of the Department of Soil Science, Land Reclamation and Geoecology, State University of Land Use Planning, Moscow Russian Federation, rochyomin@list.ru, ORCID ID: 0000-0002-5899-5464;

G. G. Morkovkin – Professor of the Department of Soil Science, Land Reclamation and Geoecology, Doctor of Agricultural Sciences, Professor, State University of Land Use Planning, Moscow Russian Federation, ggmark@mail.ru, ORCID ID: 0000-0001-8830-7135.

Вклад авторов: Н. М. Почёмин – сбор и анализ климатических данных, подготовка иллюстраций, написание статьи. Г. Г. Морковкин – формирование основной концепции, целей и задач исследований, анализ результатов.

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

Contribution of the authors: N. M. Pochemin – collected and analyzed the climate data, prepared illustrations and wrote the article. G. G. Morkovkin – developed the main concept, goals and objectives of the research and analyzed the results.

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

Пути повышения эффективности орошаемого земледелия. 2025. Т. 97, № 3. С. 187–202.
Ways of Increasing the Efficiency of Irrigated Agriculture. 2025. Vol. 97, no. 3. P. 187–202.

*Авторы заявляют об отсутствии конфликта интересов.
The authors declare no conflicts of interests.*

*Статья поступила в редакцию 25.09.2025; одобрена после рецензирования 13.10.2025;
принята к публикации 22.10.2025.
The article was submitted 25.09.2025; approved after reviewing 13.10.2025; accepted for
publication 22.10.2025.*