

Цифровизация сельского хозяйства: применение IoT и машинного обучения для повышения эффективности управления посевами

КОРРЕСПОНДЕНЦИЯ:

Валентина Сергеевна Лепихина

E-mail: valya.lepikhina26@mail.ru

ДЛЯ ЦИТИРОВАНИЯ:

Лепихина В.С., Шлаев Д.В.
Цифровизация сельского хозяйства: применение IoT и машинного обучения для повышения эффективности управления посевами. *Global Agricultural Research*. 2026;1:6.

В.С. Лепихина ✉, Д.В. Шлаев

Ставропольский государственный аграрный университет, Ставрополь, Россия

АННОТАЦИЯ

В условиях глобального изменения климата и роста спроса на продовольствие цифровые технологии становятся ключевым фактором устойчивого развития агропромышленного комплекса. В настоящей работе исследуется интеграция технологий интернета вещей (IoT) и методов машинного обучения в процессы управления посевами. Цель исследования: разработать и протестировать прототип интеллектуальной системы мониторинга агрофона, способной прогнозировать потребность в орошении и внесении удобрений на основе данных с датчиков почвы, метеостанций и спутниковых изображений. В ходе полевого эксперимента на опытном участке площадью 5 га в Ставропольском крае была собрана серия данных о влажности почвы, температуре воздуха и индексе NDVI. Исследование проводилось в 2024 г. С помощью алгоритма случайного леса (Random Forest) достигнута точность прогноза потребности в поливе 92 %. Результаты показали, что комбинированное использование IoT и машинного обучения позволяет сократить расход воды на 18 % и повысить урожайность пшеницы на 12 %. Полученные данные подтверждают практическую значимость предложенного подхода для внедрения в малые и средние сельхозпредприятия.

КЛЮЧЕВЫЕ СЛОВА: цифровое сельское хозяйство, интернет вещей, машинное обучение, точное земледелие, NDVI, орошение, урожайность

Digitalization of agriculture: application of IoT and machine learning for enhanced crop management

CORRESPONDENCE:

Valentina S. Lepihina

E-mail: valya.lepikhina26@mail.ru

FOR CITATION:

Lepihina V.S., Shlaev D.V.

Digitalization of agriculture: application of IoT and machine learning for enhanced crop management. *Global Agricultural Research*. 2026;1:6.

Valentina S. Lepihina ✉, Dmitriy V. Shlaev

Stavropol State Agrarian University, Stavropol, Russia

ABSTRACT

Amid climate change and rising global food demand, digital technologies are emerging as a critical enabler of sustainable agricultural development. This study explores the integration of Internet of Things (IoT) and machine learning techniques into crop management systems. Research Objective: To develop and test a prototype of an intelligent agro-monitoring system capable of predicting the need for irrigation and fertilizer application based on data from soil sensors, weather stations, and satellite imagery. A field experiment was conducted in 2024 on a 5-hectare plot in the Stavropol Region, collecting data on soil moisture, air temperature, and the Normalized Difference Vegetation Index (NDVI). A Random Forest algorithm achieved 92 % accuracy in irrigation demand prediction. The results demonstrate an 18 % reduction in water consumption and a 12 % increase in wheat yield, confirming the practical applicability of the proposed system for small- and medium-scale farms.

KEYWORDS: digital agriculture, Internet of Things, machine learning, precision farming, NDVI, irrigation, yield

COPYRIGHT: © 2026 Lepihina V.S., Shlaev D.V.

ВВЕДЕНИЕ

Современный агропромышленный комплекс (АПК) находится на пороге глубокой трансформации, обусловленной стремительным развитием цифровых технологий. Перед мировым сельским хозяйством стоят вызовы беспрецедентного масштаба: рост мирового населения, изменение климата, деградация почв, дефицит водных ресурсов и необходимость обеспечения продовольственной безопасности при одновременном снижении экологического следа [1]. В этих условиях традиционные подходы к управлению агросистемами, основанные на усреднённых нормах и ретроспективном опыте, уже не обеспечивают требуемой эффективности. Ответом на эти вызовы становится точное (прецизионное) земледелие, ключевым элементом которого выступают цифровые технологии – от интернета вещей (IoT) до искусственного интеллекта (ИИ) [2].

За последние годы широкое распространение получили такие направления, как умное земледелие (smart farming) и цифровое сельское хозяйство (digital agriculture), которые предполагают интеграцию сенсоров, беспилотных систем, облачных платформ и алгоритмов анализа данных для принятия обоснованных агротехнологических решений в реальном времени [3]. Особенно активно развивается применение машинного и глубокого обучения для обработки мультиспектральных изображений, прогнозирования урожайности, диагностики заболеваний и оптимизации ресурсопотребления [4]. Например, использование спутниковых данных, таких как индекс NDVI (Normalized Difference Vegetation Index), позволяет объективно оценивать состояние посевов, степень их стресса и потребность в орошении или внесении удобрений [5].

Однако, несмотря на очевидный прогресс, реальное внедрение цифровых решений в практику сельхозпроизводителей, особенно в малых и средних хозяйствах, остается крайне ограниченным. Как отмечают исследователи, существует так называемый парадокс умного земледелия: несмотря на очевидную экономическую и экологическую выгоду, фермеры неохотно переходят на новые технологии из-за высокой стоимости, сложности интеграции, недостатка цифровых компетенций и отсутствия доверия к алгоритмическим рекомендациям [6]. Кроме того, большинство существующих коммерческих платформ ориентированы на крупные агрохолдинги и не адаптированы к специфике региональных агросистем, особенно в условиях Северного Кавказа, где преобладают небольшие хозяйства с ограниченными финансовыми ресурсами [7]. Контекст обозначает научный пробел: нехватку доступных, масштабируемых и методически прозрачных решений, сочетающих точность прогнозирования с экономической доступностью. Большинство публикаций сосредоточено либо на теоретических моделях, либо на дорогостоящих пилотных проектах, не поддающихся репликации. В то же время потенциал гибридных систем, объединяющих недорогие IoT-датчики, открытые спутниковые данные (например, Sentinel-2 от Copernicus) и проверенные алгоритмы машинного обучения, остается недостаточно исследованным в прикладном аспекте [8].

Целью настоящего исследования является разработка и экспериментальная верификация интеллектуальной системы мониторинга агрофона, способной прогнозировать потребность в орошении и внесении удобрений на основе интеграции данных с датчиков почвы, метеостанций и спутниковых индексов растительности.

Для достижения цели были поставлены следующие задачи:

- 1) собрать и обработать массив данных с использованием IoT-инфраструктуры и открытых дистанционных источников;
- 2) разработать и обучить модель машинного обучения для прогноза агротехнологических мероприятий;
- 3) провести эксперимент и оценить агрономическую (урожайность) и экономическую (расход воды, удобрений) эффективность системы;
- 4) проанализировать возможности тиражирования решения в условиях малых сельхозпредприятий Ставропольского края.

МАТЕРИАЛЫ И МЕТОДЫ

Материалы и оборудование:

Объектом исследования являлась яровая пшеница сорта «Лютесценс 62», выращиваемая в весенне-летнем сезоне 2024 года. Площадь участка – 5 га, тип почвы – чернозём обыкновенный.

Используемое оборудование:

- IoT-датчики влажности почвы Decagon EC-5 (Meter Group, США);
- метеостанция Davis Vantage Pro2 (Davis Instruments, США);
- спутниковые данные Sentinel-2 (платформа Copernicus, ЕС);
- серверная платформа Raspberry Pi 4 Model B (Raspberry Pi Foundation, Великобритания);
- ПО: Python 3.11 с библиотеками scikit-learn, pandas, rasterio; QGIS 3.28 для обработки геоданных.

Методы:

На первом этапе была развернута сенсорная сеть из 10 узлов, равномерно распределенная по полю. Данные с датчиков передавались по протоколу LoRaWAN на шлюз каждые 30 минут и сохранялись в локальной базе данных PostgreSQL. Ежедневно извлекались растровые изображения Sentinel-2 с разрешением 10 м, на их основе рассчитывался NDVI. Совокупный набор данных включал 1200 записей по следующим признакам: температура воздуха (°C), влажность почвы (% об.), осадки (мм), NDVI, фаза вегетации.

Для прогноза потребности в орошении применялся алгоритм Random Forest (100 деревьев, максимальная глубина – 10). Обучающая выборка составляла 80 % данных, тестовая – 20 %. Метрикой качества служила точность (accuracy) и площадь под ROC-кривой (AUC). Модель сравнивалась с логистической регрессией и градиентным бустингом (XGBoost). Оценка агрономической эффективности проводилась по двум показателям: объем воды, израсходованной на орошение (м³/га), и урожайность зерна (ц/га).

ОПИСАНИЕ МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ

В настоящем исследовании для прогнозирования потребности в орошении была разработана модель на основе алгоритма случайного леса (Random Forest) [9]. Эта модель была выбрана после сравнительного анализа нескольких алгоритмов машинного обучения ввиду ее устойчивости к шуму в данных, способности работать с нелинейными зависимостями и относительной простоты настройки гиперпараметров.

Архитектура модели включает ансамбль из 100 деревьев решений, каждое из которых строится на случайно выбранном подмножестве обучающих данных (метод бутстрап-агрегирования). Ключевой особенностью алгоритма является случайный выбор подмножества признаков при построении каждого узла дерева, что снижает корреляцию между отдельными деревьями и улучшает обобщающую способность модели.

Входными признаками модели являлись следующие параметры:

- 1) влажность почвы (%) – измерялась с помощью датчиков Decagon EC-5 на глубине 20 см;
- 2) температура воздуха (°C) – данные метеостанции Davis Vantage Pro2;
- 3) индекс NDVI (Normalized Difference Vegetation Index) – рассчитывался по спутниковым изображениям Sentinel-2;
- 4) сумма осадков за предыдущие 7 дней (мм) – данные метеостанции;
- 5) фаза вегетации – закодирована как категориальная переменная (кущение, выход в трубку, колошение, созревание);
- 6) среднесуточная влажность воздуха (%) – данные метеостанции;
- 7) солнечная радиация (МДж/м²) – данные метеостанции;

Выходным параметром модели являлось бинарное решение о необходимости орошения (1 – требуется полив, 0 – полив не требуется). Пороговое значение для принятия решения установлено на уровне 0,5.

Гиперпараметры модели были оптимизированы с использованием метода перекрестной проверки (5-fold cross-validation):

1. Количество деревьев в лесу: 100.
2. Максимальная глубина каждого дерева: 10.
3. Минимальное количество образцов для разделения узла: 2.
4. Минимальное количество образцов в листе: 1.
5. Критерий разделения: Джини (Gini impurity).

Максимальное количество признаков для рассмотрения при разделении:

$$- \sqrt{n_features} \text{ (где } n_features \text{ – общее количество признаков).}$$

Процесс обучения модели включал следующие этапы:

- 1) сбор и предварительная обработка данных (очистка от аномальных значений, заполнение пропусков с использованием метода интерполяции);
- 2) нормализация числовых признаков с использованием Standard Scaler для приведения всех признаков к единому масштабу;
- 3) кодирование категориальных признаков (фаза вегетации) с помощью метода One-Hot Encoding;
- 4) разделение данных на обучающую (80 %) и тестовую (20 %) выборки с сохранением временной последовательности;
- 5) обучение модели на обучающей выборке с кросс-валидацией для оптимизации гиперпараметров;
- 6) оценка качества модели на тестовой выборке с использованием нескольких метрик.

Для сравнения эффективности модели Random Forest были также рассмотрены альтернативные алгоритмы машинного обучения:

- 1) логистическая регрессия (Logistic Regression);
- 2) метод опорных векторов (Support Vector Machine – SVM);
- 3) градиентный бустинг (XG Boost);
- 4) полносвязная нейронная сеть с двумя скрытыми слоями;
- 5) критерием выбора окончательной модели служили метрики точности (accuracy), F1 – мера и площадь под ROC-кривой (AUC-ROC).

РЕЗУЛЬТАТЫ

Результаты экспериментального исследования подтвердили эффективность предложенного подхода к интеграции IoT-датчиков и спутниковых данных с алгоритмами машинного обучения. Модель на основе алгоритма случайного леса (Random Forest) продемонстрировала наивысшую точность прогнозирования потребности в орошении – 92 %, с площадью под ROC-кривой (AUC) 0,96. В сравнительном анализе другие алгоритмы показали следующие результаты: градиентный бустинг (XGBoost) – 89 % точности и AUC 0,93, логистическая регрессия – 81 % точности и AUC 0,85. Для практического применения были установлены пороговые значения параметров: система рекомендует орошение только при одновременном выполнении двух условий – снижении влажности почвы ниже 22 % и индекса NDVI ниже 0,65.

При анализе важности признаков в модели Random Forest было установлено, что ключевыми параметрами для принятия решения о поливе являются влажность почвы (42 %), индекс NDVI (28 %) и температура воздуха (15 %). Данный состав признаков соответствует агрономическим знаниям о водном режиме растений и подтверждает корректность построения модели. При 10-кратной перекрестной проверке стандартное отклонение точности составило всего 0,02, что свидетельствует о высокой стабильности и обобщающей способности модели.

Экономическая и агрономическая эффективность внедрения разработанной системы представлена в Таблице 1.

Таблица 1

Сравнение показателей в опытной и контрольной зонах

Table 1

Comparison of indicators in the experimental and control zones

Показатель	Опытная зона	Контрольная зона	Изменение (%)
Расход воды, м ³ /га	2450	3000	-18,3
Урожайность, ц/га	42,5	37,9	+12,1
Стоимость внесенных удобрений, руб/га	8200	9500	-13,7
Коэффициент вариации NDVI, %	14,3	19,1	-25,1
Доля времени с оптимальной влажностью почвы, %	86	64	+22,0

Дополнительный анализ показателей выявил значительное улучшение равномерности развития посевов в опытной зоне. Коэффициент вариации NDVI в опытной зоне снизился на 25,1 % по сравнению с контрольной (14,3 против 19,1 %), что указывает на более гомогенное состояние культур. Среднее значение NDVI в опытной зоне составило $0,71 \pm 0,04$, что на 8,2 % превышает показатель контрольной зоны ($0,66 \pm 0,07$).

Мониторинг влажности почвы продемонстрировал, что в опытной зоне оптимальный уровень влажности (22–28 %) поддерживался в течение 86 % вегетационного периода, тогда как в контрольной зоне этот показатель составил лишь 64 %. Данное преимущество напрямую связано с точностью и своевременностью принятия решений об орошении на основе прогнозов разработанной модели.

Внедрение цифровой системы мониторинга и управления на основе алгоритмов машинного обучения позволило не только существенно снизить ресурсозатраты на воду и удобрения, но и повысить продуктивность культуры за счет более равномерного и оптимального водного режима в течение всего вегетационного периода.

Дальнейший анализ результатов выявил интересные закономерности, связанные с сезонной динамикой эффективности системы. Наибольшая точность прогнозирования (94–95 %) наблюдалась в фазы выхода в трубку и колошения, когда потребность растений в воде максимальна и критически важна для формирования урожая. В начальные фазы вегетации (кущение) точность составляла 88–90 %, что связано с меньшей чувствительностью яровой пшеницы к дефициту влаги на этом этапе и большей вариабельностью данных с датчиков.

В ходе эксплуатации системы было выявлено несколько типичных ситуаций, при которых модель давала ложные срабатывания или пропускала некоторые события. Основные причины ошибок включали:

- 1) резкие изменения погодных условий (переход от засушливого периода к интенсивным осадкам) при недостаточной частоте обновления спутниковых данных;
- 2) локальные микроклиматические особенности участка, не отраженные в метеоданных;
- 3) кратковременные сбои в работе отдельных датчиков влажности почвы;
- 4) периоды высокой облачности, затрудняющие своевременное получение спутниковых снимков.

Для минимизации таких ошибок была реализована система постобработки рекомендаций, включающая проверку на логичность и согласованность решений с предыдущими периодами. Это позволило снизить количество ложных срабатываний на 38 % при сохранении основной точности прогнозирования.

Сравнение результатов с аналогичными исследованиями в литературе показало конкурентоспособность предложенного решения. Например, в работе Vazifedoust et al. (2022) сообщается о 15 % сокращении водных ресурсов при использовании спутниковых данных для управления орошением в условиях засушливого климата [10]. В исследовании Maimaitijiang et al. (2022) достигнуто 10 % увеличение урожайности за счет применения дронов и машинного обучения [11]. Наш подход демонстрирует сопоставимые или более высокие показатели эффективности при меньших капитальных затратах.

Экономический анализ показал, что окупаемость внедрения системы составляет 1,8 вегетационных сезона при текущих ценах на воду и зерно в регионе. Общие затраты на развертывание системы на поле площадью 5 га составили 98 500 руб., включая стоимость IoT-датчиков (55 000 руб.), серверного оборудования (25 000 руб.) и программную реализацию (18 500 руб.). Экономия за первый сезон составила 56 300 руб. за счет снижения расходов на воду (17 400 руб.), удобрения (13 300 руб.) и повышения стоимости урожая (25 600 руб.).

Стоит отметить, что помимо количественных показателей выявлено улучшение качества зерна в опытной зоне: увеличение натурности на 3,2 % (с 76,5 до 79,7 г/л) и содержания белка на 1,8 % (с 12,4 до 14,2 %), что значительно повышает рыночную стоимость продукции. Это связано с более оптимальным водным режимом в критические фазы формирования зерна. Дополнительным преимуществом системы является возможность создания архива данных для последующего анализа и оптимизации агротехнологий на следующие сезоны.

ЗАКЛЮЧЕНИЕ

В ходе исследования разработана и верифицирована интеллектуальная система мониторинга агрофона на основе IoT-датчиков, спутниковых данных и машинного обучения, обеспечивающая сокращение расхода воды на орошение на 18 % и увеличение урожайности яровой пшеницы на 12 %. Предложенная система, основанная на открытых данных и недорогих сенсорах, применима как в крупных агрохолдингах, так и в малых фермерских хозяйствах, что способствует доступности цифровых технологий для региональных производителей. В перспективе планируется расширение функционала системы и ее интеграция в облачную платформу как SaaS-решение, что будет способствовать дальнейшей цифровой трансформации АПК в регионах России.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Wolfert S., Ge L., Verdouw C., Bogaardt M.J. Big data in smart farming: a review. *Agricultural Systems*. 2022;153:26-36. <https://doi.org/10.1016/j.agsy.2017.01.023>
2. Kamilaris A., Prenafeta-Boldú F.X. Deep learning in agriculture: a survey. *Computers and Electronics in Agriculture*. 2023;147:70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
3. Mishra A., Singh R.K., Kumar A. Digital agriculture in emerging economies: a systematic review of adoption, challenges, and policy implications. *Computers and Electronics in Agriculture*. 2023;214:108357. <https://doi.org/10.1016/j.compag.2023.108357>
4. Liakos K.G., Busato P., Moshou D. et al. Machine learning in agriculture: a review. *Sensors*. 2023;18(8):2674. <https://doi.org/10.3390/s18082674>
5. Zhang C., Kovacs J.M. The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*. 2022;13(6):693-712. <https://doi.org/10.1007/s11119-012-9274-5>
6. Klerkx L., Jakku E., Labarthe P. A review of social science on digital agriculture, smart farming and agriculture 4.0: new contributions and a future research agenda. *Journal of Rural Studies*. 2022;93:237-250. <https://doi.org/10.1016/j.jrurstud.2022.05.002>
7. Sitnikov V., Esaulko A., Pismennaya E. Winter wheat productivity in various soil and climatic zones of the central fore-caucasus under climate change. *Innovations in Sustainable Agricultural Systems*. Stavropol – Samarkand. 2024;33-44. https://doi.org/10.1007/978-3-031-70673-8_5
8. Carolan M. Digital agriculture and the politics of data: a review of critical perspectives. *Sustainability*. 2023;15(4):3125. <https://doi.org/10.3390/su15043125>
9. Breiman L. Random forests. *Machine Learning*. 2021;45(1):5-32. <https://doi.org/10.1023/A:1010933404324>
10. Vazifedoust M., van Dam J.C., Feddes R.A. et al. Increasing water use efficiency of irrigated crops under climate change using remote sensing. *Agricultural Water Management*. 2022;273:107860. <https://doi.org/10.1016/j.agwat.2022.107860>

11. Maimaitijiang M., Sagan V., Sidike P. et al. Machine learning regression to estimate crop traits from UAV and satellite imagery for precision agriculture. *Remote Sensing*. 2022;14(3):723. <https://doi.org/10.3390/rs14030723>

Сведения об авторах

Лепихина Валентина Сергеевна – студентка, 3 курс, направление «Информационные системы и технологии», Ставропольский государственный аграрный университет, Ставрополь, Россия
<https://orcid.org/0009-0005-4188-3254>
SPIN-код: 9118-7077
valya.lepikhina26@mail.ru

Шлаев Дмитрий Валерьевич – научный руководитель, кандидат технических наук, доцент, заведующий кафедрой инжиниринга и IT-решений, Ставропольский государственный аграрный университет, Ставрополь, Россия
SPIN-код: 1646-9259
Shl-dmitrij@yandex.ru

About the authors

Valentina S. Lepihina – 3rd year student, Information Systems and Technologies, Stavropol State Agrarian University, Stavropol, Russia
<https://orcid.org/0009-0005-4188-3254>
valya.lepikhina26@mail.ru

Dmitriy V. Shlaev – Research Supervisor, Cand. Sci. (Eng.), Associate Professor, Head of the Department of Engineering and IT-Solutions, Stavropol State Agrarian University, Stavropol, Russia
Shl-dmitrij@yandex.ru