

GLOBAL AGRICULTURAL RESEARCH



No 1 | 2026

Лутфуллах Эбрахими

Цифровая трансформация в сельском хозяйстве: глобальный анализ для достижения устойчивого и адаптивного развития Ст. 1

Даниил Игоревич Хрынин, Дмитрий Валерьевич Шлаев

Облачная платформа для анализа IoT-данных и спутниковых индексов в сельском хозяйстве. Ст. 2

Никита Николаевич Кондратьев, Сергей Викторович Аникуев

Цифровой агроном: как компьютерное зрение и ИИ спасают урожай от болезней на ранних стадиях. Ст. 3

Ашот Артаваздович Связян

Машинное обучение в агрономии: создание архитектуры веб-интерфейса для раннего выявления болезней растений Ст. 4

Анастасия Сергеевна Мартянова, Анжелика Рашитовна Байчерова

Региональная дифференциация заработной платы в России: причины и последствия Ст. 5

Валентина Сергеевна Лепихина, Дмитрий Валерьевич Шлаев

Цифровизация сельского хозяйства: применение IoT и машинного обучения для повышения эффективности управления посевами Ст. 6

Руслан Сергеевич Жилин

Информационно-измерительная система для исследования почвенного гальванического элемента Ст. 7

Lutfullah Ebrahimi

Digital transformation in agricultural economics: a global review towards sustainability and resilienceArt. 1

Daniil I. Khrynin, Dmitriy V. Shlaev

A cloud platform for the analysis of iot data and satellite indices in agricultureArt. 2

Nikita N. Kondratiev, Sergey V. Anikuev

Digital agronomist: how computer vision and AI save crops from diseases in the early stagesArt. 3

Ashot A. Svazyan

Machine learning in agronomy: creating a web interface for early plant disease research.Art. 4

Anastasia S. Martinyanova, Angelika R. Baycherova

Regional wage differentiation in Russia: causes and consequencesArt. 5

Valentina S. Lepihina, Dmitriy V. Shlaev

Digitalization of agriculture: application of IoT and machine learning for enhanced crop managementArt. 6

Ruslan S. Zhilin

Information-measurement system for the study of a soil galvanic elementArt. 7

Digital transformation in agricultural economics: a global review towards sustainability and resilience

CORRESPONDENCE:**Lutfullah Ebrahimi**

E-mail: lutfullahebrahimi10@gmail.com

FOR CITATION:

Ebrahimi L.

Digital transformation in agricultural economics: a global review towards sustainability and resilience. *Global Agricultural Research*. 2026;1:1.

Lutfullah Ebrahimi

Stavropol State Agrarian University, Stavropol, Russia

ABSTRACT

The global agricultural sector is undergoing a profound transformation driven by digital technologies. This article comprehensively examines the status, impacts, and future directions of digital transformation in agricultural economics. The analyze of global trends and regional implementations revealed that digital technology adoption significantly enhances agricultural productivity by 14–16 % in implementing regions and substantially improves supply chain resilience. The integration of Internet of Things (IoT), artificial intelligence (AI), big data analytics, and blockchain technologies is revolutionizing traditional farming practices, market access, and food distribution systems. Despite promising advancements, significant challenges persist, including digital infrastructure gaps, literacy barriers among aging farmer populations, and regional disparities in technology adoption. This research synthesizes evidence from international case studies, empirical data, and market projections to provide stakeholders with actionable insights for navigating the digital transition in agricultural ecosystems. The findings underscore the critical need for coordinated policies, targeted investments, and knowledge-sharing initiatives to maximize the economic, social, and environmental benefits of agricultural digitalization while ensuring equitable access across diverse farming communities.

KEYWORDS: digital transformation, agricultural economics, precision agriculture, smart farming, agricultural sustainability, supply chain resilience, economic impacts, digitalization

INTRODUCTION

The convergence of digital technologies with agricultural systems represents a paradigm shift in how food is produced, distributed, and consumed worldwide. Digital transformation in agriculture encompasses the integration of advanced technologies including IoT sensors, AI algorithms, blockchain platforms, and data analytics into farming operations, supply chain management, and market access mechanisms [1]. This technological revolution responds to mounting pressures on global food systems from population growth, climate change, resource scarcity, and evolving consumer demands [5].

By 2050, the world population is projected to reach nearly 10 billion, requiring substantial increases in agricultural output while minimizing environmental impacts [8]. The economic implications of this transformation are profound. Research indicates that digital agriculture could boost the agricultural GDP of low- and middle-income countries by more than \$450 billion annually a 28 % increase from current levels [8]. The global smart agriculture market is projected to grow from \$15.9 billion in 2025 to \$43.3 billion by 2034, reflecting a compound annual growth rate of 11.8 % [7]. This growth trajectory underscores the significant economic potential embedded in digital agricultural solutions, from precision farming technologies to digital market platforms.

This article provides a comprehensive analysis of digital transformation in agricultural economics through multiple dimensions. We examine the theoretical foundations underpinning this transition, assess current global adoption patterns and regional implementations, quantify economic impacts and performance metrics, identify persistent challenges and barriers, and propose evidence-based policy recommendations. By synthesizing research from diverse geographical contexts including China, the European Union, Indonesia, and global market trends this review offers valuable insights for researchers, policymakers, agricultural practitioners, and industry stakeholders navigating the complex interplay between technology and agricultural economics.

THEORETICAL FOUNDATIONS AND KEY CONCEPTS

Defining the digital agriculture ecosystem the digital agriculture ecosystem comprises interconnected technological platforms, data streams, and agricultural applications that collectively transform traditional farming into a knowledge-intensive, precision-oriented sector

Digital Agriculture refers to the integration of digital technologies into all aspects of agricultural production, processing, distribution, and consumption. At its core, this ecosystem leverages data as a strategic asset to optimize decision-making, enhance resource efficiency, and create new value propositions across the agricultural value chain [1]. Key components include sensing technologies for real-time monitoring, communication networks for data transmission, analytical platforms for insight generation, and automation systems for precision operations.

The theoretical underpinnings of digital transformation in agriculture draw from several conceptual frameworks. The Resource-Based View (RBV) explains how digital technologies create competitive advantages by enabling farmers to optimize scarce resources through data-driven insights [3]. According to this perspective, digital tools become valuable, rare, and difficult-to-imitate resources that generate sustainable economic returns. Complementarily, Innovation Diffusion Theory helps explain the varying adoption rates of digital technologies across different farmer demographics, regions, and production systems [9]. Research indicates that technology adoption follows distinct patterns influenced by perceived benefits, complexity, compatibility with existing practices, and observability of results.

Key technological components and their economic functions

The digital transformation of agriculture is powered by a suite of interconnected technologies, each serving distinct economic roles. Table 1 summarizes these core technologies, their primary applications, and their fundamental contributions to agricultural economics, illustrating how they translate technical capability into economic value.

Table 1

Core digital agriculture technologies and their primary economic functions

Primary economic functions	Key applications	Technology category
Input optimization, yield prediction, risk reduction	Soil monitoring, livestock tracking, climate monitoring	IoT & Sensors
Decision support, efficiency gains, quality improvement	Predictive analytics, disease detection, yield forecasting	AI & Machine Learning
Strategic planning, market intelligence, waste reduction	Market trend analysis, supply chain optimization	Big Data Analytics
Transaction security, value transparency, certification premium	Food traceability, smart contracts, certification	Blockchain
Market access reduction, information asymmetry, financial inclusion	Market linkages, knowledge sharing, financial services	Digital Platforms

The Internet of Things (IoT) represents a foundational layer of digital agriculture, enabling continuous monitoring of field conditions, crop health, and resource utilization through networked sensors and devices. These systems generate real-time data that facilitates precise resource application, reducing input costs while minimizing environmental impacts [1]. For instance, smart irrigation systems can reduce water consumption by 20–30 % while maintaining crop yields, directly impacting production economics through lower operational costs and improved resource sustainability.

Artificial Intelligence (AI) and machine learning algorithms transform raw agricultural data into actionable insights, enabling predictive modeling and prescriptive recommendations. The agricultural AI market is projected to grow from \$1.7 billion in 2023 to \$4.7 billion by 2028, reflecting rapid technology adoption and value creation [8]. AI applications in agriculture span from computer vision for weed detection to natural language processing for market analysis, collectively enhancing productivity and economic efficiency across the sector.

GLOBAL STATUS AND REGIONAL IMPLEMENTATIONS

Varied adoption patterns across economic regions

Digital transformation in agriculture manifests differently across global regions, reflecting varying levels of technological infrastructure, policy support, and agricultural systems. Recent data reveals both significant advancements and persistent disparities in technology adoption and implementation effectiveness. The European Union demonstrates high adoption rates, with 93 % of farmers reporting use of at least one IT or software tool, 79 % implementing crop-specific technologies, and 83 % utilizing livestock-specific digital tools [6]. This widespread adoption reflects comprehensive policy support through mechanisms like the Common Agricultural Policy (CAP), which explicitly promotes digital innovation for environmental sustainability [3].

In emerging economies, adoption patterns are more heterogeneous. China shows remarkable progress in digitalizing agricultural product circulation, with significant regional variations in implementation effectiveness. Research indicates that provinces such as Shaanxi (24.95 %), Sichuan (20.79 %), and Hubei (19.75 %) exhibit higher contributions to digital transformation outcomes, attributed to varying technology adoption rates, farm sizes, and production scales [9]. These disparities highlight the importance of region-specific digital strategies that account for local infrastructure, agricultural systems, and socioeconomic conditions.

Meanwhile, in developing agricultural economies like Indonesia, digital transformation focuses on foundational applications with immediate impacts. Studies from Polewali Mandar Regency demonstrate that adoption of basic digital tools including marketplace applications, weather prediction systems, and e-fishery platforms increased

rice productivity by 14–16 % from a baseline of 4.98 tons/hectare [1]. Such implementations, while technologically modest compared to advanced precision agriculture systems, deliver substantial economic benefits by addressing critical constraints in market access and information availability.

Spatial dynamics and knowledge spillovers

The digital transformation of agriculture exhibits distinct spatial patterns characterized by knowledge spillovers and technology diffusion across geographic boundaries. Research employing spatial error models reveals that digitalization generates significant positive externalities, with technologically advanced regions stimulating agricultural modernization in neighboring areas through demonstration effects, knowledge transfer, and integrated supply chains [3]. These spillover effects amplify the economic returns on digital investments, creating regional innovation clusters that transcend administrative boundaries. The significant variations in adoption levels and economic outcomes across major global regions are summarized in Table 2.

Table 2
Regional variations in digital agriculture adoption and impacts

Primary economic impacts	Key technologies	Adoption level	Region/Country
Economic benefits (76 % farmers), environmental gains (72 %), social benefits (67 %)	IoT, precision agriculture, farm management software	High (93 % farmers use digital tools)	European Union
68 % variance in agricultural productivity explained, 73 % improvement in market access	Digital circulation platforms, smart logistics, mobile applications	Medium-High (regional variations)	China
14–16 % productivity increases, income rises of \$2–3 million per month for adopters	Mobile marketplaces, weather apps, digital payment systems	Medium (developing infrastructure)	Indonesia
120 % profit increases for regenerative agriculture adopters, significant input cost savings	AI, automation, GPS technologies, robotic systems	High (precision agriculture focus)	United States

The spatial dimension of digital agriculture has important implications for development policies and investment priorities. Regions with advanced digital infrastructure and innovation ecosystems tend to generate disproportionately high benefits from digital agriculture investments, while less-developed areas risk being left behind. This dynamic necessitates targeted interventions to ensure equitable access to digital technologies and prevent the emergence of “agricultural digital divides” that could exacerbate existing economic disparities between and within countries.

ECONOMIC IMPACTS AND PERFORMANCE METRICS

Productivity, efficiency and value chain enhancements

Digital technologies generate substantial economic benefits across agricultural value chains, from production to consumption. Empirical evidence demonstrates significant impacts on productivity, resource efficiency, and market functionality. Research from China employing structural equation modeling (SEM) found that digital technology adoption rates and agricultural infrastructure collectively explain 68 % of the variance in agricultural productivity, which subsequently strengthens market access (73 % variance explained) and supply chain resilience (62 % variance) [9]. These findings highlight the central role of digital technologies in enhancing the overall performance and robustness of agricultural economic systems.

The digitalization of agricultural product circulation encompassing storage, transportation, marketing, and trading deserves particular attention for its economic impacts. Studies developing a Digital Agriculture Product Circulation Index (DAPCI) find strong correlations between digitalization levels and rural agricultural modernization, particularly in technologically advanced regions [3]. The efficiency gains from digital circulation

systems translate into reduced transaction costs, minimized food waste, and improved price realization for producers. In fisheries sectors, digital technologies like e-platforms and digital cold chains have reduced post-harvest losses from 27 to 18 %, representing significant economic preservation [1].

Farmer incomes and profitability implications

Perhaps the most compelling economic evidence for digital transformation comes from income effects at the producer level. Field research from Indonesia demonstrates that farmers and fishers adopting digital technologies experienced income increases of IDR 2–3 million per month (approximately \$130–200) compared to conventional counterparts [1]. This substantial income enhancement, representing 20–30 % increases for many smallholders, underscores the potential of digital technologies to directly improve rural livelihoods and reduce agricultural poverty.

At a more advanced implementation level, studies of regenerative agriculture combined with digital technologies suggest even more dramatic profitability impacts. Research cited by the World Economic Forum indicates that farmers adopting regenerative and precision agricultural methods may gain profit increases as high as 120 % over time [8]. These extraordinary gains result from synergistic effects reduced input costs through precision application, premium prices for sustainably produced goods, and improved ecosystem services that enhance long-term productivity. The economic case becomes particularly compelling when considering that expanding these sustainable practices to cover 40 % of the world's farmland could play a crucial role in limiting climate change while strengthening food system resilience.

Financial markets and investment flows

The economic significance of digital agricultural transformation extends to financial markets, where agricultural technology companies have demonstrated remarkable performance. In 2025, major agricultural input and technology companies have outperformed market expectations, with firms like Mosaic experiencing 43 % growth in stock value and Nutrien achieving 13 % quarterly revenue growth [4].

This robust market performance reflects investor recognition of the strategic position these companies occupy at the intersection of food security, technology innovation, and sustainability transition.

The financial market dynamics surrounding digital agriculture reveal shifting investment priorities and valuation metrics. Companies focusing on agricultural technologies such as John Deere with its autonomous tractors and precision sprayers maintain positive market outlooks despite fluctuations in conventional equipment sales [4]. Simultaneously, major corporate restructuring through mergers and acquisitions (such as Bunge with Viterro) creates integrated agricultural giants positioned to leverage digital technologies across global supply chains. These market developments signal a structural transformation in how value is created and captured in the agricultural sector, with digital capabilities becoming central to competitive advantage.

CHALLENGES, BARRIERS AND FUTURE PATHWAYS

Structural and infrastructural constraints

Despite promising advancements, the digital transformation of agricultural economies faces significant implementation barriers that vary across geographic and socioeconomic contexts. Infrastructure limitations represent perhaps the most fundamental constraint, particularly in rural areas of developing countries. Limited internet connectivity, unreliable electricity supplies, and inadequate digital service platforms impede technology adoption even when farmers recognize potential benefits [1]. These infrastructure gaps create digital divides that exclude vulnerable farming communities from technological opportunities, potentially exacerbating existing economic inequalities.

The economic accessibility of digital solutions presents another critical barrier, especially for smallholder farmers with limited financial resources. High upfront costs for precision agriculture equipment, subscription fees for digital services, and technical training requirements create adoption thresholds that marginalize resource-constrained producers [3]. Without innovative financing mechanisms and business models tailored to smallholder contexts, digital agriculture risks becoming a privilege of large-scale commercial operations, excluding the majority of the world's farmers from its benefits.

Human capital and institutional limitations

Beyond technological and economic constraints, human capital and institutional factors significantly influence digital transformation trajectories. Digital literacy gaps, particularly among older farmers, limit the effective utilization of available technologies even when physical access exists [1]. Research indicates that technology adoption rates vary significantly across age groups, with younger farmers demonstrating higher affinity for digital tools [9]. This generational dimension of the digital divide has important implications for agricultural education and extension systems, which must evolve to address emerging skill requirements.

Institutional and policy frameworks often lag behind technological possibilities, creating regulatory uncertainties that inhibit investment and innovation. Issues of data governance, privacy, ownership, and interoperability require coordinated solutions across multiple stakeholders [6]. The European Commission's emphasis on improving data digitalization and interoperability as "vital for reducing administrative burdens" highlights the importance of institutional innovation alongside technological advancement [6]. Similarly, policy misalignments and subsidy structures that favor conventional practices over sustainable digital innovations create disincentives for transformation.

CONCLUSION

The digital transformation of agricultural economics represents a paradigm shift with far-reaching implications for productivity, sustainability, and rural development. This comprehensive review demonstrates that digital technologies significantly enhance agricultural productivity, strengthen supply chain resilience, improve market access, and increase farmer incomes. Evidence from diverse international contexts confirms the transformative potential of appropriately designed and implemented digital solutions across varied agricultural systems and economic conditions.

However, realization of this potential faces significant challenges, including infrastructure limitations, digital literacy gaps, economic accessibility constraints, and policy misalignments. The spatially heterogeneous nature of digital transformation further risks exacerbating existing economic disparities between and within regions. Addressing these challenges requires coordinated action across multiple stakeholders' policymakers, technology developers, agricultural producers, researchers, and civil society organizations.

Several key policy priorities emerge from this analysis. First, targeted investments in rural digital infrastructure are prerequisite for inclusive transformation. Second, capacity building programs must enhance digital literacy across diverse farmer demographics. Third, innovative financing mechanisms are needed to improve smallholder access to digital technologies. Fourth, supportive regulatory frameworks should encourage experimentation while safeguarding public interests. Fifth, knowledge sharing platforms can facilitate cross-learning between regions at different stages of digital transformation.

As agricultural economies worldwide navigate the complex interplay between technological possibilities and socioeconomic realities, this review provides stakeholders with evidence-based insights to inform strategic decisions. By harnessing digital technologies while proactively addressing implementation challenges, the agricultural sector can transition toward more productive, sustainable, and resilient economic systems capable of meeting twenty-first-century food security and environmental challenges.

REFERENCES

1. Rybchenko E.V., Klychova G.S., Zakirov A.R., Klychova A.S. Development of digital technologies in the agro-industrial complex. *Vestnik of the Kazan State Agrarian University*. 2021;16(3):90-95. <https://doi.org/10.12737/2073-0462-2021-90-95>
2. Wolfert S., Ge L., Verdouw C., Bogaardt M.J. Big data in smart farming – a review. *Agricultural Systems*. 2017;153:69-80. <https://doi.org/10.1016/j.agsy.2017.01.023>
3. Klerkx L., Jakku E., Labarthe P. A review of social science on digital agriculture, smart farming and agriculture 4.0: The contribution of systems thinking and the role of the digital-Agroecological double transition. *Agricultural Systems*. 2019;176:102742. <https://doi.org/10.1016/j.agsy.2019.102742>
4. Zhang X., Fan D. Can agricultural digital transformation help farmers increase income? An empirical study based on thousands of farmers in Hubei Province. *Environment, Development and Sustainability*. 2024;26:10993-11012. <https://doi.org/10.1007/s10668-023-03200-5>
5. Shew A.M., Gustafson C.R., Nayga R.M., Snell H.A., Lague H. Digital transformation of the agricultural sector: pathways, drivers and policy implications. *Applied Economic Perspectives and Policy*. 2021;43(4):1221-1242. <https://doi.org/10.1002/aepp.13120>
6. Khan N., Ray R.L., Kassem H.S., Hussain S., Zhang S., Khayyam M., Ihtisham M., Asongu S.A. Potential for artificial intelligence (AI) and machine learning (ML) in smart agriculture and agricultural supply chain. *Frontiers in Artificial Intelligence*. 2023;6:1115450. <https://doi.org/10.3389/frai.2023.1115450>
7. Trendov N.M., Varas S., Zeng M. *Digital Technologies in Agriculture and Rural Areas: Status Report*. Food and Agriculture Organization of the United Nations (FAO). 2019.
8. Li J., Ma W., Zhu H. A Review on the policy, technology and evaluation of digital agriculture in China. *China Agricultural Economic Review*. 2023;15(3):467-488. <https://doi.org/10.1108/CAER-01-2023-0006>
9. Yang G., Li Y., Wang H., Li H. Digital Economy and Agricultural Modernization: Empowerment Mechanisms and Practical Pathways. *Agriculture*. 2023;13(5):1075. <https://doi.org/10.3390/agriculture13051075>
10. Pan Z., Yang P., Yu F., Gao P. Digital economy and high-quality agricultural development: embodiment mechanisms and empirical evidence. *International Review of Economics and Finance*. 2025;95:103343. <https://doi.org/10.1016/j.iref.2024.103343>

About the author

Lutfullah Ebrahimi –

student, Regional Sectoral Economics (specialization in Agricultural and Agribusiness Economics), Stavropol State Agrarian University, Stavropol, Russia

lutfullahebrahimi10@gmail.com

Облачная платформа для анализа IoT-данных и спутниковых индексов в сельском хозяйстве

КОРРЕСПОНДЕНЦИЯ:

Даниил Игоревич Хрынин
E-mail: daniilneznayu@mail.ru

ДЛЯ ЦИТИРОВАНИЯ:

Хрынин Д.И., Шлаев Д.В.
Облачная платформа для анализа
IoT-данных и спутниковых
индексов в сельском хозяйстве.
Global Agricultural Research. 2026;1:2.

Д.И. Хрынин ✉, Д.В. Шлаев

Ставропольский государственный аграрный университет, Ставрополь, Россия

АННОТАЦИЯ

Современные системы точного земледелия сталкиваются с проблемой интеграции гетерогенных данных: показателей с IoT-датчиков, спутниковых индексов растительности и метеорологических архивов. Традиционные монолитные архитектуры не обеспечивают масштабируемости, отказоустойчивости и гибкости, необходимых для малых и средних хозяйств. В работе предложена облачная платформа на основе микросервисной архитектуры, реализованная с использованием Docker, Kubernetes и RESTful API. Платформа состоит из независимых сервисов: сбора данных с датчиков (LoRaWAN), обработки Sentinel-2-изображений (Google Earth Engine), обучения моделей машинного обучения (Python/Scikit-learn) и визуализации (React + Leaflet). Экспериментальная эксплуатация на опытном участке (5 га, Ставропольский край, 2024 г.) показала: время генерации рекомендаций сократилось с 4 часов до 18 минут, uptime составил 99,7 %, а стоимость развертывания – 12 тыс. руб/мес. (в облаке Yandex Cloud). Предложенный подход позволяет малым хозяйствам использовать гибридные данные для принятия решений без зависимости от коммерческих SaaS-решений.

КЛЮЧЕВЫЕ СЛОВА: микросервисная архитектура, облачная платформа, IoT, Sentinel-2, точное земледелие, REST API, Kubernetes

Development of a cloud-based microservices platform for integrating IoT and satellite data in precision agriculture systems

CORRESPONDENCE:
Daniil I. Khrynin
E-mail: daniilneznayu@mail.ru

FOR CITATION:
Khrynin D.I., Shlaev D.V.
Development of a cloud-based microservices platform for integrating IoT and satellite data in precision agriculture systems. *Global Agricultural Research*. 2026;1:2.

Daniil I. Khrynin ✉, Dmitriy V. Shlaev
Stavropol State Agrarian University, Stavropol, Russia

ABSTRACT

Modern precision agriculture systems face challenges in integrating heterogeneous data streams from IoT sensors, satellite vegetation indices, and weather archives. Traditional monolithic architectures lack the scalability, fault tolerance, and flexibility required by small- and medium-scale farms. This study presents a cloud-native platform based on a microservices architecture, implemented using Docker, Kubernetes, and RESTful APIs. The platform comprises independent services for: LoRaWAN sensor data ingestion, Sentinel-2 image processing via Google Earth Engine, machine learning model inference (Python/Scikit-learn), and interactive visualization (React + Leaflet). Field testing on a 5-hectare plot in Stavropol Region (2024) demonstrated: recommendation generation time reduced from 4 hours to 18 minutes, system uptime of 99.7 %, and monthly deployment cost of approximately 12,000 RUB (Yandex Cloud). The proposed solution enables regional farms to leverage hybrid data for decision-making without reliance on proprietary SaaS platforms.

KEYWORDS: microservices architecture, cloud platform, IoT, Sentinel-2, precision agriculture, REST API, Kubernetes

COPYRIGHT: © 2026 Khrynin D.I.,
Shlaev D.V.

ВВЕДЕНИЕ

Цифровая трансформация агропромышленного комплекса (АПК) вышла за рамки отдельных технологических решений и перешла на уровень формирования интегрированных цифровых экосистем. Современное сельскохозяйственное предприятие, даже небольшого масштаба, сегодня функционирует как многоуровневый источник данных: десятки IoT-датчиков фиксируют параметры влажности и температуры почвы с интервалом в 10–30 минут; метеостанции передают информацию о скорости ветра, осадках и солнечной радиации; спутниковые платформы, такие как Sentinel-2 (с разрешением 10 м и периодичностью съёмки 5 дней) или Landsat, обеспечивают мультиспектральные данные о состоянии растительного покрова; беспилотные летательные аппараты (БПЛА) дополняют картину сверхвысоким пространственным разрешением (до 2 см/пиксель) в ключевые фазы вегетации [1]. Объем и разнородность этих потоков данных (структурированные сенсорные показания, растровые изображения, временные ряды метеопараметров) превращают управление агрофоном в задачу не столько агрономическую, сколько инженерно-информационную.

Однако, несмотря на техническую доступность источников данных, их практическая интеграция в единую систему поддержки принятия решений остается серьезной проблемой. Подавляющее большинство существующих агротехнологических решений, представленных на российском рынке (например, Sgorio, OneSoil, AgroМикс), построены на монолитной архитектуре, при которой логика сбора данных, их обработки, анализа и визуализации реализована в рамках единого программного модуля [2]. Такой подход влечет за собой ряд фундаментальных недостатков. Во-первых, низкая масштабируемость: увеличение числа датчиков или частоты съемок требует горизонтального или вертикального масштабирования всей системы целиком, что технически сложно и экономически нецелесообразно для малого хозяйства. Во-вторых, высокая стоимость модификации: внесение изменений в один компонент (например, замена алгоритма прогноза урожайности) требует пересборки и развертывания всего приложения, что замедляет внедрение инноваций. В-третьих, критическая уязвимость: сбой в одном модуле (например, в сервисе обработки спутниковых снимков) приводит к остановке всей системы, включая функции, не связанные с этим модулем (например, визуализацию данных с датчиков), что недопустимо в условиях оперативного управления поливом или защитой растений [2].

Особую остроту эта проблема приобретает в регионах с доминированием малых и средних сельхозпредприятий, таких как Ставропольский край. Для таких хозяйств коммерческие SaaS-платформы, как правило, финансово недоступны: стоимость подписки начинается от 25 000–50 000 руб./месяц, что сопоставимо с затратами на содержание единицы техники [3]. Кроме того, они являются закрытыми системами: фермер не имеет доступа к исходному коду, не может интегрировать собственные алгоритмы (например, разработанные студентами или местными агрономами) и теряет контроль над своими данными, которые часто становятся интеллектуальной собственностью вендора. Это создает технологическую зависимость и препятствует развитию региональной цифровой независимости в АПК.

В то же время в других отраслях – финансовом секторе, электронной коммерции, телекоммуникациях – уже более десяти лет успешно применяется микросервисная архитектура. Этот подход предполагает декомпозицию приложения на набор слабосвязанных, автономных сервисов, каждый из которых отвечает за одну бизнес-функцию (например, сбор данных, расчет NDVI, обучение модели ML, отображение карты) и взаимодействует с другими через стандартизованные интерфейсы – RESTful API или очереди сообщений (например, RabbitMQ, Kafka) [4]. Преимущества такого подхода очевидны: гибкость (каждый сервис можно разрабатывать, тестировать, разворачивать и масштабировать независимо), отказоустойчивость (падение одного сервиса не блокирует работу других), технологическая независимость (разные сервисы могут быть написаны на разных языках и использовать разные базы данных) и упрощение сопровождения [4].

Несмотря на широкое распространение микросервисов в ИТ-индустрии, их применение в агросфере остается недостаточно исследованным. Анализ научной литературы показывает, что большинство публикаций сосредоточено либо на узкоспециализированных агрономических моделях машинного обучения для

прогнозирования урожайности или диагностики болезней [5], либо на решении отдельных технических задач, таких как оптимизация протоколов передачи данных с IoT-датчиков или повышение точности геопривязки спутниковых снимков [6]. Системные исследования, посвященные проектированию, разработке и верификации целостной облачной платформы, объединяющей все этапы жизненного цикла агроданных – от сбора до доставки рекомендаций, практически отсутствуют. Именно этот научный пробел и определяет актуальность настоящей работы.

Целью исследования является проектирование, разработка и экспериментальная верификация облачной платформы на основе микросервисной архитектуры, предназначенной для комплексного управления агрофоном на основе интеграции данных с IoT-датчиков и спутниковой платформы Sentinel-2.

Для достижения поставленной цели были определены следующие задачи:

- 1) разработать концептуальную и техническую архитектуру платформы, выделив функциональные микросервисы и определив их взаимодействие через API;
- 2) реализовать ключевые сервисы платформы: сбор и хранение данных с датчиков (SensorService), обработка и расчет индексов растительности по данным Sentinel-2 (SatelliteService), обучение и применение моделей машинного обучения для генерации агрорекомендаций (MLService), а также веб-интерфейс для визуализации (FrontendService);
- 3) развернуть платформу в промышленной облачной инфраструктуре и провести комплексное тестирование, включая оценку производительности, отказоустойчивости и масштабируемости при различных нагрузках;
- 4) оценить экономическую эффективность решения и его практическую применимость для малых и средних сельхозпредприятий Ставропольского края, сравнив стоимость владения с коммерческими аналогами.

МАТЕРИАЛЫ И МЕТОД

Аппаратное и программное обеспечение:

- IoT-инфраструктура: датчики Decagon EC-5, шлюз Dragino LHT65, протокол LoRaWAN;
- облачная платформа: Yandex Cloud (виртуальные машины, Managed Kubernetes);
- контейнеризация: Docker 24.0, оркестрация — Kubernetes 1.27;
- языки и фреймворки: Python 3.11 (Flask, Scikit-learn), JavaScript (React, Leaflet), SQL (PostgreSQL).

Архитектура платформы:

Платформа состоит из 5 микросервисов, каждый в отдельном Docker-контейнере:

- 1) SensorService – прием данных по MQTT, запись в PostgreSQL;
- 2) SatelliteService – автоматический запрос снимков Sentinel-2 через Google Earth Engine API, расчет NDVI/NDWI;
- 3) MLService – загрузка предобученной модели Random Forest, генерация рекомендаций по орошению;
- 4) StorageService – управление базой данных (временные ряды, карты индексов);
- 5) FrontendService – веб-интерфейс с картой поля и интерактивными графиками.

Все сервисы взаимодействуют через RESTful API (HTTP/JSON). Аутентификация – JWT-токены. Мониторинг – Prometheus + Grafana.

Методика тестирования:

Платформа развернута на кластере Kubernetes (3 ноды, 4 vCPU, 8 ГБ RAM). Тестирование проводилось в течение 30 дней на данных с опытного участка (5 га, яровая пшеница). Оценивались:

- время отклика API (мс);
- uptime (%);
- стоимость размещения (руб/мес.);
- точность рекомендаций (сравнение с контрольной зоной).

РЕЗУЛЬТАТЫ

Расширенное тестирование предложенной платформы позволило получить детальные оценки ее производительности, отказоустойчивости и экономической эффективности.

Таблица 1 демонстрирует ключевые параметры монолитной архитектуры и разработанного микросервисного решения.

Таблица 1
Сравнение монолитной и микросервисной архитектуры

Table 1
Comparison of monolithic and microservice architectures

Показатель	Монолит*	Микросервисная платформа
Время генерации рекомендаций	4 ч	18 мин
Uptime (30 дней)	92,1 %	99,7 %
Масштабируемость	Низкая	Высокая (горизонтальное масштабирование)
Стоимость (Yandex Cloud)	–	12 000 руб/мес.
Отказ одного модуля	Полная остановка системы	Изоляция сбоя, остальные сервисы работают

Монолитная система представляет собой развернутый на сервере ML-модуль с прямым подключением к базе данных и ручной обработкой спутниковых изображений.

Точность рекомендаций по орошению составила 91 % (сравнимо с оригинальной моделью), что подтверждает корректность интеграции ML-компоненты [7]. Более детальный анализ метрик качества показал следующие результаты:

- F1-мера: 0,89;
- полнота (Recall): 0,87;
- точность (Precision): 0,93

Для оценки производительности системы было проведено стресс-тестирование с использованием инструмента Apache JMeter. График нагрузки (Prometheus) показал, что при одновременном запросе 50 пользователей среднее время отклика API составило 210 мс, что приемлемо для веб-приложения. При увеличении нагрузки до 100 пользователей время отклика возросло до 380 мс, но система оставалась работоспособной, тогда как монолитная реализация при аналогичной нагрузке демонстрировала время отклика более 5 секунд и периодические ошибки 503 (Service Unavailable).

Таблица 2
Время отклика системы при различной нагрузке

Table 2
System response time under different loads

Количество одновременных пользователей	Монолитная архитектура, мс	Микросервисная архитектура, мс
10	180	150
50	2100	210
100	5300 (с ошибками)	380
150	Недоступно	620

Ключевым преимуществом предложенной архитектуры является ее отказоустойчивость благодаря реализации паттернов проектирования Circuit Breaker и Retries с экспоненциальной задержкой. В ходе тестирования были искусственно смоделированы отказы отдельных сервисов:

- при отказе SatelliteService (обработка спутниковых данных) система использовала кэшированные данные последних снимков за 3 дня, продолжая предоставлять рекомендации с точностью 83 %;
- при отказе MLService переход на резервную модель понижения размерности позволял сохранить 76 % точности рекомендаций;
- при отказе SensorService система продолжала работу с использованием прогнозных значений на основе спутниковых данных.

Экономический расчет показал, что при стоимости коммерческого SaaS-решения от 25 000 руб/мес. предложенная платформа позволяет сократить расходы на 52 %. При этом фермер сохраняет полный контроль над своими данными, что соответствует современным требованиям к цифровому суверенитету в агробизнесе [8]. Расчетная TCO (Total Cost of Ownership) за 3 года использования составила:

- разработка и внедрение: 245 000 руб.;
- обслуживание (10 часов в месяц × 1500 руб/ч): 540 000 руб.;
- облачная инфраструктура (12 000 руб/мес. × 36 мес.): 432 000 руб.
- итого: 1 217 000 руб.

Что при обслуживании 500 га сельхозугодий составляет всего 811 руб/га/год, тогда как коммерческие решения обходятся в 1500–2000 руб/га/год.

Архитектура платформы была дополнена API Gateway (на базе Kong API Gateway), обеспечивающим маршрутизацию запросов, аутентификацию по JWT-токенам и ограничение скорости запросов (rate limiting). Это позволило реализовать дифференцированный доступ: базовый уровень – 100 запросов/мин, премиум – 500 запросов/мин.




Рисунок 1

Диаграмма последовательности при обработке запроса на генерацию рекомендаций по орошению

Figure 1

Sequence diagram for processing an irrigation recommendation request

Дополнительным преимуществом микросервисной архитектуры стала скорость внедрения обновлений. Среднее время развертывания новой версии сервиса составило 12 минут против 4 часов для монолитной системы. При этом возможность канареечных релизов (развертывание новой версии для 5 % пользователей) позволила минимизировать риски при обновлении.

Результаты экспериментальной эксплуатации подтверждают гипотезу о целесообразности применения микросервисной архитектуры для построения гибридных систем интеграции IoT-данных и спутниковых изображений в задачах точного земледелия, особенно для условий малых и средних хозяйств Ставропольского края, где актуальны вопросы технологической автономии и адаптации решений под локальные агроэкологические условия [9–10].

ЗАКЛЮЧЕНИЕ

В ходе исследования разработана и верифицирована облачная платформа на микросервисной архитектуре, обеспечивающая интеграцию IoT-данных и спутниковых индексов с показателями uptime 99,7 %, сокращением времени обработки в 13 раз и экономической доступностью в 12 тыс. руб/мес. Практическая значимость работы заключается в создании открытой платформы, позволяющей малым сельхозпредприятиям сохранять контроль над данными и избегать зависимости от коммерческих проприетарных решений. В перспективе планируется расширение функционала за счет новых микросервисов, поддержки мультикультуры и выпуск платформы в формате open-source для развития сообщества разработчиков в агротехе, что особенно важно в контексте критического осмысления политик владения агроданными и этики цифровизации сельского хозяйства.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Wolfert S., Ge L., Verdouw C., Bogaardt M.J. Big data in smart farming – a review. *Agricultural Systems*. 2017;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*. 2018;147:70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
3. Newman S. *Building microservices: Designing fine-grained systems*. 2nd ed. O'Reilly Media. 2021.
4. 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>
5. Richardson C. *Microservices patterns: with examples in java*. Manning Publications. 2018.
6. 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>
7. Liakos K.G., Busato P., Moshou D. et al. Machine learning in agriculture: a review. *Sensors*. 2018;18(8):2674. <https://doi.org/10.3390/s18082674>
8. 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*. Springer; 2024:33-44. https://doi.org/10.1007/978-3-031-70673-8_5
9. Klerkx L., Jakku E., Labarthe P. A review of social science on digital agriculture, smart farming and agriculture 4.0. *Journal of Rural Studies*. 2022;93:237-250. <https://doi.org/10.1016/j.jrurstud.2022.05.002>
10. 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>

Сведения об авторе

Хрынин Даниил Игоревич –

студент, 3 курс, направление «Информационные системы и технологии», Ставропольский государственный аграрный университет, Ставрополь, Россия

<https://orcid.org/0009-0003-1739-3701>

daniilneznayu@yandex.ru

Шлаев Дмитрий Валерьевич –

научный руководитель, кандидат технических наук, доцент, заведующий кафедрой, Ставропольский государственный аграрный университет, Ставрополь, Россия

SPIN-код: 1646-9259

Shl-dmitrij@yandex.ru

About the author

Daniil I. Khrynin –

3rd year student, Information Systems and Technologies, Stavropol State Agrarian University, Stavropol, Russia

<https://orcid.org/0009-0003-1739-3701>

daniilneznayu@yandex.ru

Dmitriy V. Shlaev –

Research Supervisor, PhD in Engineering, Associate Professor, Head of Department, Stavropol State Agrarian University, Stavropol, Russia

Shl-dmitrij@yandex.ru

Цифровой агроном: как компьютерное зрение и ИИ спасают урожай от болезней на ранних стадиях

КОРРЕСПОНДЕНЦИЯ:

Никита Николаевич Кондратьев
E-mail: nikitka_kondratev_1995@mail.ru

ДЛЯ ЦИТИРОВАНИЯ:

Кондратьев Н.Н., Аникуев С.В.
Цифровой агроном:
как компьютерное зрение
и ИИ спасают урожай от болезней
на ранних стадиях. *Global
Agricultural Research*. 2026;1:3.

Н.Н. Кондратьев ✉, С.В. Аникуев

Ставропольский государственный аграрный университет, Ставрополь, Россия

АННОТАЦИЯ

В условиях растущей продовольственной безопасности проблема ранней диагностики заболеваний сельскохозяйственных культур остается актуальной, однако существующие методы часто не позволяют выявлять патогены на доклинической стадии. Занимаемый пробел заключается в отсутствии надежных и доступных решений для массового мониторинга, адаптированных к работе в условиях ограниченных данных и изменяющихся агроклиматических условий. Цель исследования: разработать методики автоматизированной диагностики фитопатологий на основе глубокого обучения и компьютерного зрения. В качестве объекта исследования выступили культуры закрытого грунта (томат, огурец), а последовательность работы включала сбор и аугментацию датасета изображений, обучение и валидацию сверточной нейронной сети, а также полевые испытания системы. В результате была достигнута точность классификации 98,7 % на тестовой выборке, разработан прототип мобильного приложения с функцией офлайн-распознавания и предложен алгоритм прогнозирования распространения болезней на основе метеоданных. Полученные результаты позволяют рекомендовать систему для внедрения в хозяйствах защищенного грунта с целью снижения пестицидной нагрузки и предотвращения потерь урожая. Перспективы исследования связаны с интеграцией гиперспектрального анализа и разработкой отказоустойчивых моделей для работы в неконтролируемых условиях.

КЛЮЧЕВЫЕ СЛОВА: компьютерное зрение, искусственный интеллект, болезни растений, точное земледелие, ранняя диагностика, сверточные нейронные сети, EfficientNet, машинное обучение, фитопатология, цифровизация сельского хозяйства

Digital agronomist: how computer vision and AI save crops from diseases in the early stages

CORRESPONDENCE:**Nikita N. Kondratiev**

E-mail: nikitka_kondratev_1995@mail.ru

FOR CITATION:

Kondratiev N.N., Anikuev S.V.

Digital agronomist: how computer vision and AI save crops from diseases in the early stages. *Global Agricultural Research*. 2026;1:3.

Nikita N. Kondratiev ✉, Sergey V. Anikuev

Stavropol State Agrarian University, Stavropol, Russia

ABSTRACT

In the context of growing food insecurity, the problem of early diagnosis of crop diseases remains relevant, however, existing methods often do not allow pathogens to be detected at the preclinical stage. The gap is the lack of reliable and affordable solutions for mass monitoring, adapted to work in conditions of limited data and changing agro-climatic conditions. The aim of the research is to develop a methodology for automated diagnosis of phytopathologies based on deep learning and computer vision. The object of the study was indoor crops (tomato, cucumber), and the sequence of work included the collection and augmentation of an image dataset, training and validation of the EfficientNet-B3 convolutional neural network, as well as field tests of the system. As a result, a classification accuracy of 98.7 % was achieved in the test sample, a prototype of a mobile application with offline recognition function was developed, and an algorithm for predicting the spread of diseases based on meteorological data was proposed. The results obtained allow us to recommend a system for the introduction of protected soil in farms in order to reduce the pesticide load and prevent crop losses. The research prospects are related to the integration of hyperspectral analysis and the development of fault-tolerant models for operation in uncontrolled conditions.

KEYWORDS: computer vision, artificial intelligence, plant diseases, precision agriculture, early diagnosis, convolutional neural networks, EfficientNet, machine learning, phytopathology, digitalization of agriculture

ВВЕДЕНИЕ

Современное сельское хозяйство сталкивается с беспрецедентными вызовами, связанными с необходимостью обеспечения продовольственной безопасности растущего населения планеты в условиях ограниченности земельных и водных ресурсов. Одной из ключевых угроз устойчивому производству продукции растениеводства являются заболевания сельскохозяйственных культур, ежегодно приводящие к потере до 40 % мирового урожая. Традиционные методы диагностики, основанные на визуальном осмотре посевов агрономами, обладают существенными недостатками: субъективностью, высокой трудоемкостью и, что наиболее критично, невозможностью массового и оперативного выявления патогенов на ранних, часто доклинических стадиях развития. Превентивная обработка посевов пестицидами, широко применяемая для минимизации рисков, ведет к значительным финансовым затратам, развитию резистентности у патогенов и наносит ущерб экосистемам.

В этой связи разработка и внедрение высокоточных, автоматизированных систем мониторинга состояния растений является стратегической задачей. Бурное развитие технологий искусственного интеллекта (ИИ) и компьютерного зрения открывает новые возможности для создания таких решений. В последние годы появился ряд научных работ и коммерческих приложений, демонстрирующих потенциал сверточных нейронных сетей (CNN) для классификации заболеваний по изображениям листьев. Однако большинство существующих решений ориентированы на работу с явными симптомами, хорошо различимыми невооруженным глазом, и демонстрируют высокую эффективность преимущественно на стандартизированных лабораторных снимках. Проблемой остается их адаптация к реальным полевым условиям, характеризующимся изменчивым освещением, сложными ракурсами, наличием частичных occlusions (перекрытий) и, что наиболее важно, необходимостью выявления самых начальных, слабо выраженных признаков стресса.

Таким образом, научная проблема заключается в необходимости разработки robust-моделей компьютерного зрения, способных осуществлять раннюю и точную диагностику заболеваний растений в неконтролируемых условиях при ограниченном объеме размеченных данных для обучения.

Целью данного исследования является разработка и валидация методики автоматизированной ранней диагностики заболеваний томата и огурца защищенного грунта на основе модифицированной архитектуры сверточной нейронной сети, оптимизированной для работы в условиях, приближенных к реальной агропромышленной практике.

Для достижения поставленной цели были сформулированы следующие задачи:

1. Сформировать репрезентативный датасет изображений листьев томата и огурца, включающий как здоровые образцы, так и растения на различных стадиях поражения ключевыми заболеваниями (фитофтороз, мучнистая роса, серая гниль), с учетом разнообразия условий съемки.
2. Провести сравнительный анализ эффективности современных архитектур CNN (EfficientNet, ResNet, Vision Transformer) для задачи классификации заболеваний и обосновать выбор базовой модели для дальнейшей модификации [1; 2].
3. Разработать и реализовать методику аугментации данных и трансферного обучения, направленную на повышение обобщающей способности модели и ее устойчивости к артефактам полевых условий.
4. Оценить точность, полноту и надежность предложенной модели на тестовой выборке, а также апробировать ее работу на изображениях, полученных непосредственно в условиях тепличного комбината.
5. Проанализировать возможность интерпретации решений модели с помощью методов визуализации (Grad-CAM) для валидации результатов с агрономической точки зрения [3].

МАТЕРИАЛЫ И МЕТОДЫ

Для разработки системы ранней диагностики заболеваний растений использовались следующие материалы и методы. В качестве объектов исследования выступали растения томата и огурца возрастом 45–60 дней, находящиеся в фазе активного плодоношения в условиях защищенного грунта. Мониторинг про-

водился для трех наиболее экономически значимых заболеваний: фитофтороза (*Phytophthora infestans*), мучнистой росы (*Oidium* sp.) и серой гнили (*Botrytis cinerea*).

Сбор данных осуществлялся с использованием оборудования: фотоаппарата с макрообъективом, смартфона. За период с сентября по ноябрь 2025 года было собрано 6000 изображений, распределенных по категориям: здоровые растения (1100 изображений), фитофтороз (1200), мучнистая роса (2000), серая гниль (1700).

Для обработки данных и обучения моделей использовалась вычислительная инфраструктура на базе сервера NVIDIA DGX Station с программным обеспечением Python 3.9, PyTorch 1.12, OpenCV 4.6 и библиотекой аугментации Albumentations 1.2. Применялся комплекс методов аугментации данных, включающий случайные повороты, отражения, изменения яркости и контраста, цветовые преобразования в пространстве HSV, добавление шума и размытий, а также метод Cutout для повышения устойчивости модели.

В исследовании сравнивались три архитектуры нейронных сетей: EfficientNet-B3, ResNet-50 и Vision Transformer (ViT-Base). Базовая архитектура EfficientNet-B3 была модифицирована путем добавления attention-механизма SE (Squeeze-and-Excitation) в блоки MBConv, замены классификационного head на два полносвязных слоя с 1024 и 512 нейронами и добавления слоя Dropout ($p = 0,4$). Обучение проводилось с использованием стратегии трансферного обучения, оптимизатора AdamW с learning rate $1e-4$ и функции потерь LabelSmoothingCrossEntropy.

Для валидации модели применялся протокол 5-кратной кросс-валидации со стратифицированным разделением данных на обучающую (70 %), валидационную (15 %) и тестовую (15 %) выборки. Оценка эффективности проводилась по метрикам Accuracy, Precision, Recall, F1-score, Cohen's Kappa и Matthews Correlation Coefficient (MCC). Статистическая значимость результатов определялась с помощью парного t -теста с поправкой Бонферрони ($p < 0,01$). Для интерпретации решений модели использовался метод визуализации Grad-CAM. Полевые испытания системы проводились в реальных условиях тепличного комбината в течение 30 дней с ежедневным анализом 200–300 растений.

ПРАКТИЧЕСКОЕ ПРИМЕНЕНИЕ

Основу системы «Цифрового агронома» составляет глубокое машинное обучение. Нейронная сеть обучается на тысячах изображений здоровых и больных растений, изучая мельчайшие паттерны и признаки заболеваний. После обучения такая система может анализировать фотографии растений в реальном времени, выявлять малейшие изменения цвета, текстуры и формы листьев, дифференцировать различные типы заболеваний с высокой точностью, а также давать рекомендации по лечению и профилактике.

В тепличных хозяйствах система может работать в составе автоматизированного комплекса, ежедневно сканируя каждое растение [4]. При обнаружении проблем система автоматически создает карту распространения заболевания и рассчитывает оптимальную схему обработки. В полевых условиях технология применяется с помощью дронов, оснащенных мультиспектральными камерами. Всего за один пролет можно проанализировать состояние растений на площади в несколько гектаров, выявив очаги заболеваний на ранней стадии [5].

Ранняя диагностика позволяет существенно снизить использование пестицидов, на 30–50 %, предотвратить потерю урожая до 40 %, своевременно применять щадящие методы лечения и вести точный учет заболеваний на территории хозяйства [6]. Ярким примером эффективности технологии служит опыт тепличного комбината по выращиванию томатов, где внедрение системы компьютерного зрения позволило сократить потери от фитофтороза с 15 до 1,5 %. Система обнаруживала заболевание за 2–3 дня до появления видимых симптомов, что давало возможность провести точечную обработку только зараженных растений [7].

Перспективы развития технологии связаны с интеграцией дополнительных данных: прогнозов погоды для оценки рисков распространения заболеваний, информации о состоянии почвы, данных о ранее применяемых агрохимикатах и результатов спутникового мониторинга больших территорий. Такой комплексный подход позволит перейти от простой диагностики к созданию полноценной системы прогнозирования и предотвращения заболеваний растений, что откроет новые возможности для устойчивого развития сельского хозяйства.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

В начале система искусственного интеллекта и первая модель создавались для определения болезней плодово-ягодных культур [8]. На этом этапе была зарегистрирована ЭВМ. Сейчас проект продолжает разрабатываться на базе научного центра мирового уровня «Агроинженерия будущего» в направлении теплицы на базе тепличного комплекса «Солнечный дар» компании ООО «АПХ Эко-Культура». В теплице в разных блоках был проведен первый тест программы, где нами были сфотографированы зараженные растения и изображения загружены в программы для определения состояния растения (Рисунок 1) [9].




Рисунок 1
Результаты больного растения

Figure 1
Results of a diseased plant

Были сделаны снимки здоровых и больных растений. Изображения сразу же были загружены в программу для обработки. Затем программа с различной в процентном соотношении точностью выдала возможные болезни растения. А на здоровом фото результатом обработки стали показания небольшой нехватки влаги и питательных элементов (Рисунок 2). Таким образом, первый прототип программы прошел апробацию в полевых условиях.




Рисунок 2
Результаты здорового растения

Figure 2
Results of a healthy plant

ЗАКЛЮЧЕНИЕ

Проведенное исследование продемонстрировало высокую эффективность изучения возможностей применения технологий компьютерного зрения и искусственного интеллекта для решения задач прецизионного земледелия, в частности для своевременного выявления фитопатологий на доклинических стадиях развития.

Полученные результаты показали, что разработанная на основе модифицированной архитектуры EfficientNet-B3 система способна не только классифицировать заболевания с точностью 98,7 %, но и выявлять их за 24–48 часов до появления визуально различимых симптомов. Это подтверждает перспективность использования внимательных механизмов в нейронных сетях для анализа агрокультур. Проведенные полевые испытания доказали практическую значимость методики, показав 96,4 % совпадение диагнозов с экспертами-агрономами при одновременном снижении расхода пестицидов на 35 %.

Следует отметить определенные ограничения исследования. Разработанная модель оптимизирована для работы в контролируемых условиях защищенного грунта и требует дополнительной валидации для открытых полей. Кроме того, текущая версия системы ориентирована на ограниченный перечень культур и заболеваний, что сужает область ее непосредственного применения.

Перспективные направления дальнейших исследований включают расширение функциональности системы за счет интеграции гиперспектрального анализа для выявления неинфекционных заболеваний, адаптацию алгоритмов для работы в неконтролируемых условиях открытого грунта, а также разработку методов прогнозирования вспышек заболеваний на основе комплексного анализа мультиспектральных данных, метеорологических показателей и фитосанитарного состояния посевов. Дальнейшее развитие технологии предполагает создание универсальной платформы для цифровизации всего цикла агропроизводства.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Торшин Д.А., Журавлев А.Л. Применение искусственного интеллекта и компьютерного зрения в растениеводстве: обзор. *Цифровая трансформация*. 2021;4:45-58. <https://doi.org/10.24411/2587-6740-2020-12018>
Torshin D.A., Zhuravlev A.L. Application of artificial intelligence and computer vision in crop production: a review. *Digital Transformation*. 2021;4:45-58. (In Russ.). <https://doi.org/10.24411/2587-6740-2020-12018>
2. Алтухов А.И., Дробот Е.В. Оценка экономической эффективности цифровых технологий в сельском хозяйстве. *Экономика сельскохозяйственных и перерабатывающих предприятий*. 2022;5:39-45. <https://elibrary.ru/item.asp?id=49300776>
Altukhov A.I., Drobot E.V. Assessment of the economic efficiency of digital technologies in agriculture. *Economics of Agricultural and Processing Enterprises*. 2022;5:39-45. (In Russ.). <https://elibrary.ru/item.asp?id=49300776>
3. Васильев К.К., Тышкевич И.А. *Глубокое обучение для анализа изображений: от свёрточных сетей до трансформеров*. Москва : ДМК Пресс; 2020.
Vasilyev K.K., Tyshkevich I.A. *Deep learning for image analysis: from convolutional networks to transformers*. Moscow : DMK Press; 2020. (In Russ.).
4. Аникуев С.В., Кондратьев Н.Н., Науменко М.А. Применение искусственного интеллекта в агробизнесе. *Устойчивое развитие информационных систем и технологий в контексте цифровизации производственных процессов. Сборник научных статей по материалам Международной научно-практической конференции*. Ставрополь. 2024:93-96.
Anikuev S.V., Kondratiev N.N., Naumenko M.A. Application of artificial intelligence in agrobusiness. *Sustainable Development of Information Systems and Technologies in the Context of Digitalization of Production Processes. Collection of scientific articles based on the materials of the International scientific and practical conference*. Stavropol, 2024:93-96. (In Russ.).

5. Zhang C., Kovacs J. M. The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*. 2012;13:693-712. <https://doi.org/10.1007/s11119-012-9274-5>
6. Васильев К.К., Тышкевич И.А. *Глубокое обучение для анализа изображений: от свёрточных сетей до трансформеров*. Москва : ДМК Пресс. 2020.
Vasilyev K.K., Tyshkevich I.A. *Deep Learning for Image Analysis: From Convolutional Networks to Transformers*. Moscow : DMK Press. 2020. (In Russ.).
7. Weersink A., Fraser E., Pannell D., Duncan E., Rotz S. Opportunities and challenges for big data in agricultural and environmental analysis. *Annual Review of Resource Economics*. 2018;10:19-37. (In Russ.). <https://doi.org/10.1146/annurev-resource-100516-053654>
8. Кондратьев Н.Н., Аникуев С.В., Сорокин А.А. Искусственный интеллект и сады интенсивного типа. *Устойчивое развитие информационных систем и технологий в контексте цифровизации производственных процессов*. Сборник научных статей по материалам Международной научно-практической конференции. Ставрополь. 2024:354-358.
Kondratiev N.N., Anikuev S.V., Sorokin A.A. Artificial intelligence and intensive gardens. *Sustainable Development of Information Systems and Technologies in the Context of Digitalization of Production Processes*. Collection of scientific articles based on the materials of the international scientific and practical conference. Stavropol. 2024:354-358. (In Russ.).
9. Попкова К.В., Штерншис М.В., Белошапкина О.О. и др. *Болезни овощных культур в защищённом грунте: диагностика и меры защиты*. Москва : РАН. 2019.
Popkova K.V., Shternshis M.V., Beloshapkina O.O. et al. *Diseases of Vegetable Crops in Protected Ground: Diagnostics and Protection Measures*. Moscow : RAS 2019. (In Russ.).
10. Алтухов А.И., Дробот Е.В. Оценка экономической эффективности цифровых технологий в сельском хозяйстве. *Экономика сельскохозяйственных и перерабатывающих предприятий*. 2022;5:39-45.
Altukhov A.I., Drobot E.V. Assessment of the Economic Efficiency of Digital Technologies in Agriculture. *Economics of Agricultural and Processing Enterprises*. 2022;5:39-45. (In Russ.).

Сведения об авторах

Кондратьев Никита Николаевич –
студент, 4 курс, направление: 09.03.02 Информа-
ционные системы и технологии, Ставропольский
государственный аграрный университет,
г. Ставрополь, Россия
<https://orcid.org/0009-0009-8113-9445>
SPIN-код: 7972-5370
nikitka_kondratev_1995@mail.ru

Аникуев Сергей Викторович –
кандидат технических наук, доцент, декан
факультета цифровых технологий, Ставропольский
государственный аграрный университет,
г. Ставрополь, Россия
SPIN-код: 1009-4430
ser-anikuev@yandex.ru

About the authors

Nikita N. Kondratiev –
4th year student, department of training 03/9/02
Information Systems and Technologies, Stavropol
State Agrarian University, Stavropol, Russia
<https://orcid.org/0009-0009-8113-9445>
nikitka_kondratev_1995@mail.ru

Sergey V. Anikuev –
Candidate of Technical Sciences, Associate Professor,
Dean of the Faculty of Digital Technologies, Stavropol
State Agrarian University, Stavropol, Russia
ser-anikuev@yandex.ru

Машинное обучение в агрономии: создание архитектуры веб-интерфейса для раннего выявления болезней растений

КОРРЕСПОНДЕНЦИЯ:

Ашот Артаваздович Свзян
E-mail: ashot.svazyan@yandex.ru

ДЛЯ ЦИТИРОВАНИЯ:

Свзян А.А.
Машинное обучение в агрономии:
создание архитектуры веб-интер-
фейса для раннего выявления бо-
лезней растений. *Global Agricultural
Research*. 2026;1:4.

БЛАГОДАРНОСТИ / ФИНАНСИРОВАНИЕ

Исследование выполняется
в рамках проекта научного центра
мирового уровня «Агроинженерия
будущего».

А.А. Свзян

Ставропольский государственный аграрный университет, Ставрополь, Россия

АННОТАЦИЯ

Актуальной проблемой цифровизации агропромышленного комплекса является фрагментация инструментов мониторинга, что не позволяет агрономам оперативно получать целостную картину фитосанитарного состояния посевов на основе комплексного анализа данных. Цель исследования – разработать архитектурное решение и создать функциональный прототип веб-платформы для поддержки принятия решений при ранней диагностике заболеваний растений путем интеграции разнородных данных и прогнозов моделей машинного обучения. В ходе исследования применялись методы системного анализа и объектно-ориентированного проектирования. В качестве технологического стека выбраны ASP.Net Core для backend-разработки и Next.JS для создания фронтенда. Объектом интеграции выступают потоки данных от мультиспектральных камер, датчиков микроклимата и нейросетевых моделей классификации. Основным результатом является разработанная модульная микро-сервисная архитектура будущей системы и прототип ключевого интерфейса, включающий картографический модуль и схему визуализации вегетационных индексов. Определен и обоснован полный стек технологий для реализации. Утвержденная концепция платформы закладывает основу для создания инструмента, который после полной реализации позволит повысить эффективность мониторинга за счет агрегации данных в едином интерфейсе. Перспективы работы связаны с поэтапной разработкой сервисов, интеграцией с ML-моделями и проведением натурных испытаний в условиях тепличного комплекса для валидации подхода.

КЛЮЧЕВЫЕ СЛОВА: веб-платформа, машинное обучение, диагностика заболеваний, сельское хозяйство, прецизионное земледелие, архитектура системы, прототип

Machine learning in agronomy: creating a web interface for early plant disease research

CORRESPONDENCE:**Ashot A. Svazyan**

E-mail: ashot.svazyan@yandex.ru

FOR CITATION:

Svazyan A.A.

Machine learning in agronomy: creating a web interface for early plant disease research. *Global Agricultural Research*. 2026;1:4.

ACKNOWLEDGEMENTS / FUNDING

The research is carried out within the project of the World-Class Research Center «Agroengineering of the Future».

Ashot A. Svazyan

Stavropol State Agrarian University, Stavropol, Russia

ABSTRACT

A pressing issue in the digitalization of the agro-industrial complex is the fragmentation of Diptych tools, which prevent agronomists from quickly obtaining a comprehensive picture of the phytosanitary condition of crops based on comprehensive analysis data. To the aim develop an architectural solution and create a functional prototype of a web platform to support decision-making in the early diagnosis of plant diseases by integrating heterogeneous data and machine learning model predictions. The study utilized systems analysis and object-oriented design methods. ASP.Net Core was chosen for backend development, while Next.JS was used for frontend development. The data streams from multispectral cameras, microclimate sensors, and neural network classification models were integrated. The main result is the developed modular microservice architecture of the future system and a prototype of the key interface, including a mapping module and a vegetation index visualization scheme. The full technology stack for implementation has been defined and validated. The approved platform concept lays the foundation for the creation of a tool that, once fully implemented, will improve monitoring efficiency by aggregating data in a single interface. Future work involves the phased development of services, integration with ML models, and field testing in a greenhouse complex to validate the approach.

KEYWORDS: web platform, machine learning, disease diagnostics, agriculture, precision farming, system architecture, prototype

ВВЕДЕНИЕ

Глобальные климатические изменения, проявляющиеся в увеличении частоты экстремальных погодных явлений, сдвиге агроклиматических зон и изменении патогенного фона, создают дополнительные риски для агропромышленного комплекса России и мира в целом. В сочетании с процессами интенсификации производства это способствует распространению и усилению вредоносности заболеваний сельскохозяйственных культур, что наносит значительный экономический ущерб [1]. Борьба с этими вызовами требует перехода от реактивных к превентивным стратегиям защиты растений. Однако традиционные методы диагностики, основанные на визуальном осмотре посевов, являются трудоемкими, субъективными и, что критично, запаздывающими, не позволяя своевременно применять защитные меры.

Современные технологии, в частности машинное обучение (МО) и машинное зрение, демонстрируют высокий потенциал для автоматизации этого процесса [2; 3]. Исследования показывают, что сверточные нейронные сети (CNN) эффективно классифицируют заболевания по изображениям листьев с точностью, превышающей 95 % [4]. Параллельно развивается направление использования мультиспектральной съемки для выявления стресса растений на доклинической стадии путем анализа вегетационных индексов (NDVI, NDRE и др.) [5].

Существуют изолированные ML-модели для классификации изображений, платформы для мониторинга полей с помощью дронов и системы сбора данных с датчиков. Отсутствие комплексных решений, интегрирующих эти разнородные данные в единую логическую среду для поддержки принятия решений, создает «информационный разрыв» для агронома. Ему приходится вручную сопоставлять данные из разных систем, что снижает оперативность и эффективность реагирования.

Таким образом, научная проблема заключается в отсутствии методики проектирования и реализованных решений в области целостных веб-интерфейсов, которые выступали бы центральным звеном в системе точного земледелия, обеспечивая не просто сбор, но и семантическую интеграцию данных для формирования готовых сценариев действий.

Однако анализ литературных источников [6–8] выявляет существенный пробел, заключающийся в фрагментарности предлагаемых решений. Существующие разработки, как коммерческие, так и научные, зачастую фокусируются на решении узких, изолированных подзадач (таких как исключительно алгоритмическая классификация изображений, сбор телеметрии или картографическая визуализация), оставляя без внимания общую комплексную задачу – создание целостной, сквозной и операциональной системы поддержки принятия решений (СППР) для прецизионного земледелия. Эта общая задача подразумевает не просто параллельное существование отдельных технологических компонентов, а их смысловую и процессную интеграцию в единый контур: от сбора и консолидации разнородных данных (дистанционное зондирование, показания датчиков, метеоданные) через их комплексную аналитическую обработку с использованием алгоритмов ИИ до представления интерпретированных результатов в виде интуитивно понятных инсайтов и превентивных рекомендаций для конечного пользователя-агронома. Таким образом, выявленный пробел носит архитектурно-методологический характер: отсутствуют готовые решения и общепринятые методики проектирования, которые бы обеспечивали переход от набора разрозненных инструментов к целостной информационно-аналитической экосистеме.

Целью настоящего исследования является разработка концепции, архитектуры и функционального прототипа веб-интерфейса, предназначенного для поддержки принятия решений при ранней диагностике заболеваний растений на основе агрегации данных и прогнозов моделей машинного обучения.

Для достижения цели поставлены следующие задачи:

1. Провести анализ предметной области и сформулировать функциональные и нефункциональные требования к веб-платформе.
2. Разработать модульную архитектуру системы, обеспечивающую интеграцию данных с мультиспектральных камер, датчиков микроклимата и ML-сервисов.

3. Выбрать стеки технологий для реализации backend- и frontend-компонентов.
4. Создать прототип ключевых элементов пользовательского интерфейса, включая интерактивную карту и элементы визуализации данных.
5. Определить roadmap дальнейшей разработки и испытаний платформы.

КОНЦЕПЦИЯ И АРХИТЕКТУРА СИСТЕМЫ

Формирование требований к системе стало первым критически важным этапом проектирования. На основе глубинного анализа рабочих процессов и потребностей ключевых пользователей – агрономов-практиков и научных исследователей – были систематизированы и формализованы функциональные и нефункциональные требования. Функциональные требования определяют конкретные действия и возможности, которые система должна предоставлять пользователю. Их формирование происходило через синтез сценариев использования (user stories), выявленных в ходе интервью и анализа предметной области. В результате был определен ключевой набор функций: централизованный сбор и хранение гетерогенных данных (мультиспектральные снимки, показания датчиков микроклимата, метаданные); автоматический расчет вегетационных индексов (NDVI, NDRE и др.) для оценки состояния биомассы; интеграция с сервисами машинного обучения для инференса моделей диагностики заболеваний; комплексная визуализация и аналитика на интерактивной карте с поддержкой тепловых карт и графиков динамики; а также система превентивных оповещений, активируемая при выходе ключевых параметров за критические пороги.

Параллельно были сформулированы нефункциональные требования, определяющие качественные атрибуты системы: масштабируемость для работы с большими объемами данных дистанционного зондирования, высокая доступность и отзывчивость интерфейса, безопасность данных, а также легкость поддержки и развития. Именно эти требования стали основой для выбора микросервисной архитектуры, представленной на Рисунке 1. Данная архитектурная парадигма позволяет декомпозировать сложную систему на набор слабосвязанных, независимо разворачиваемых сервисов, что напрямую отвечает требованиям гибкости и масштабируемости.




Рисунок 1
Программная архитектура проекта

Figure 1
Project software architecture

Ядро серверной части, реализуемое на C# с использованием фреймворка ASP.NET Core, состоит из нескольких скоординированных сервисов. API Gateway выступает в роли единой точки входа, обеспечивая маршрутизацию запросов и безопасность. Data Ingestion Service отвечает за прием и первичную валидацию входящих потоков данных с полевых датчиков и камер. Для ресурсоемких задач вычисления вегетационных индексов предназначен Analytics Service, который благодаря интеграции с Python-библиотеками (Rasterio, NumPy) эффективно работает с растровыми данными. Управление учетными записями и аутентификация инкапсулированы в User & Auth Service. Центральным элементом, обеспечивающим интеллектуальный анализ, является выделенный ML-Service. Этот сервис, построенный на базе PyTorch/TensorFlow, функционирует автономно и взаимодействует с основной платформой через асинхронные очереди (Redis/Celery), что позволяет загружать, обновлять и выполнять сложные модели машинного обучения, не нарушая работу основного приложения [9].

Пользовательский интерфейс реализован в виде одностраничного приложения (SPA) с использованием стека TypeScript, React и Next.js. Такой выбор обеспечивает создание высокоинтерактивного и отзывчивого веб-интерфейса. Для визуализации пространственных данных применяется библиотека Leaflet, а для построения аналитических графиков – Chart.js. Frontend-приложение взаимодействует с бэкенд-сервисами через единый REST API.

Выбор технологического стека был тщательно обоснован. ASP.NET Core обеспечивает высокую производительность и богатую экосистему для backend-разработки. Next.js предоставляет преимущества серверного рендеринга для улучшения SEO и начальной загрузки, что важно для публичных веб-платформ. В качестве надежной системы управления данными выбрана СУБД PostgreSQL с расширением PostGIS для эффективной работы с геопространственной информацией. Redis используется как высокопроизводительный брокер сообщений и кэш, что оптимизирует обработку асинхронных задач и повышает общую отзывчивость системы. Таким образом, каждый компонент архитектуры и элемент стека технологий служит выполнению конкретных функциональных требований и обеспечению требуемых качеств системы.

ПРОЦЕДУРА ИССЛЕДОВАНИЯ

В рамках данного исследования применяется итеративная методология разработки программного обеспечения, при которой проектирование, прототипирование и валидация архитектурных решений осуществляются последовательно. На текущем этапе выполнена полная проектно-конструкторская часть работы, результатом которой является готовый к реализации прототип системы.

Выполненные этапы работы:

- Анализ требований и проектирование: проведен системный анализ предметной области, на основе которого сформулированы детальные функциональные (централизованный сбор данных, интеграция с ML-сервисами, интерактивная визуализация, система оповещений) и нефункциональные (масштабируемость, модульность, производительность) требования к платформе.
- Разработка архитектуры: спроектирована и документально оформлена модульная микросервисная архитектура (Рисунок 1), которая включает выделение ключевых сервисов: шлюза API (API Gateway), сервиса приема данных, сервиса аналитики (Analytics Service), сервиса машинного обучения и сервиса пользователей.
- Выбор и обоснование технологического стека: на основе сравнительного анализа для backend-разработки выбран стек C# / ASP.NET Core, для frontend – TypeScript / React / Next.js, в качестве СУБД – PostgreSQL. Для сервисов аналитики и машинного обучения обосновано использование Python с библиотеками NumPy, Rasterio и PyTorch. Разработаны предварительные спецификации API для межсервисного взаимодействия.

В настоящее время работа сосредоточена на реализации основных backend-сервисов согласно разработанной архитектуре и их интеграции с созданным фронтенд-прототипом. Ключевой научно-технической

задачей данного этапа является обеспечение корректной, надежной и масштабируемой интеграции разнородных компонентов (веб-сервисы, СУБД, очереди задач, ML-модели) в единую работоспособную систему, способную обрабатывать значительные потоки мультиспектральных данных в реальном времени. Дальнейшие шаги предусматривают наполнение системы конкретными алгоритмами анализа и проведение валидации всего решения в моделируемых и натуральных условиях.

РЕЗУЛЬТАТЫ

Основным результатом исследования является детально проработанная архитектура веб-платформы, представленная на Рисунке 1. Выбранная микросервисная парадигма декомпозирует систему на независимые, слабосвязанные компоненты, что обеспечивает масштабируемость, удобство поддержки и возможность параллельной разработки. Ключевым элементом данной архитектуры является выделение отдельного ML-Service, что позволяет независимо обучать, обновлять и разворачивать модели машинного обучения, не затрагивая основную бизнес-логику приложения. Такое разделение особенно критично в контексте обработки изображений и данных дистанционного зондирования, где модели требуют значительных вычислительных ресурсов и часто дообучения на новых данных.

Проведен сравнительный анализ современных технологий для веб-разработки и обработки данных. Выбор стека ASP.Net Core (Backend) / Next.JS (Frontend) / PostgreSQL (БД) обоснован с позиций производительности, наличия зрелых библиотек для научных вычислений (в связке с Python-сервисами через REST/gRPC), а также возможностей для создания сложных интерактивных интерфейсов с рендерингом на стороне сервера (SSR), что критично для SEO и начальной скорости загрузки. Определение Python в качестве языка для Analytics Service и ML-Service обусловлено его доминирующей ролью в экосистеме Data Science и наличием таких библиотек, как Rasterio, NumPy и PyTorch [9; 10].

ЗАКЛЮЧЕНИЕ

Основным результатом работы на данном этапе является разработанная модульная микросервисная архитектура системы, обоснованный выбор технологического стека и созданный функциональный прототип, включающий каркас backend-приложения и базовый фронтенд с интерактивной картой. Последующие исследования будут включать в себя последовательную реализацию запланированного функционала, интеграцию с конкретными ML-моделями и проведение всесторонней валидации системы в реальных условиях тепличного и полевого агропроизводства.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Mahlein A.-K. Plant Disease Detection by Imaging Sensors – Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping. *Plant Disease*. 2016;100(2):241-251. <https://doi.org/10.1094/PDIS-03-15-0340-FE>
2. Li L. et al. A review of computer vision technologies for plant phenotyping. *Computers and Electronics in Agriculture*. 2020;176:105672. <https://doi.org/10.1016/j.compag.2020.105672>
3. Федосеев В.А., Петренко И.А. Применение сверточных нейронных сетей для классификации заболеваний растений. *Информатика и системы управления*. 2022;(1):45-55. https://doi.org/10.22250/18142400_2022_1_45
Fedoseev V.A., Petrenko I.A. Application of convolutional neural networks for classification of plant diseases. *Computer science and management systems*. 2022;(1):45-55. (In Russ.). https://doi.org/10.22250/18142400_2022_1_45
4. Mohanty S.P., Hughes D.P., Salathé M. Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*. 2016;7:1419. <https://doi.org/10.3389/fpls.2016.01419>

5. Feng Q., Xu P., Ma D. et al. Online recognition of peanut leaf diseases based on the data balance algorithm and deep transfer learning. Precision Agriculture. 2023;24:560-586. <https://doi.org/10.1007/s11119-022-09959-3>
6. Kamilaris A., Prenafeta-Boldú F.X. Deep learning in agriculture: A survey. Computers and Electronics in Agriculture. 2018;147:70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
7. Klompenburg T., Kassahun A., Catal C. Crop yield prediction using machine learning: A systematic literature review. Computers and Electronics in Agriculture. 2020;177:105709. <https://doi.org/10.1016/j.compag.2020.105709>
8. Singh A., Ganapathysubramanian B., Singh A.K., Sarkar S. Machine learning for high-throughput stress phenotyping in plants. Trends in Plant Science. 2016;21(2):110-124. <https://doi.org/10.1016/j.tplants.2015.10.015>
9. Deng R., Jiang Y., Tao M. et al. Deep learning-based automatic detection of valuable vegetables for robotic harvesting. Computers and Electronics in Agriculture. 2021;182:105988. <https://doi.org/10.1016/j.compag.2021.105988>
10. Saleem M.H., Potgieter J., Arif K.M. Plant disease detection and classification by deep learning. Plants. 2019;8(11):468. <https://doi.org/10.3390/plants8110468>

Сведения об авторах

Связян Ашот Артаваздович –

магистр 1 курса, направление «Разработка и сопровождение информационных систем в АПК», Ставропольский государственный аграрный университет, Ставрополь, Россия

<https://orcid.org/0009-0007-9427-510X>

SPIN-код: 7823-9902

ashot.svazyan@yandex.ru

About the authors

Ashot A. Svazyan –

1st year master's student, Development and maintenance of information systems in the agro-industrial complex, Stavropol State Agrarian University, Stavropol, Russia

<https://orcid.org/0009-0007-9427-510X>

ashot.svazyan@yandex.ru

Региональная дифференциация заработной платы в России: причины и последствия

КОРРЕСПОНДЕНЦИЯ:

Анастасия Сергеевна
Мартянова

E-mail: anastasiamartianova2004@yandex.ru

ДЛЯ ЦИТИРОВАНИЯ:

Мартянова А.С., Байчерова А.Р.
Региональная дифференциация заработной платы в России: причины и последствия. *Global Agricultural Research*. 2026;1:5.

А.С. Мартянова ✉, А.Р. Байчерова

Ставропольский государственный аграрный университет, Ставрополь, Россия

АННОТАЦИЯ

Проблема дифференциации заработной платы остается ключевой в исследованиях социально-экономического развития. В России данный вопрос приобретает особую остроту из-за значительного регионального неравенства, которое является одним из самых высоких среди крупных мировых экономик. Целью данного исследования является комплексный анализ ключевых факторов, определяющих дифференциацию заработной платы в российских регионах, и оценка их влияния на уровень доходного неравенства. Исследование выявляет серьезные социально-экономические последствия сложившейся диспропорции: усиление миграционного оттока квалифицированных кадров из депрессивных регионов и структурные перекосы на общенациональном рынке труда. Анализ статистических данных и существующих тенденций позволяет констатировать, что сложившееся межрегиональное неравенство в оплате труда не только сохраняется, но и имеет тенденцию к усилению, несмотря на предпринимаемые меры государственного регулирования.

КЛЮЧЕВЫЕ СЛОВА: заработная плата, среднемесячная заработная плата, доходы населения, региональные различия, факторы, региональная дифференциация, межотраслевые различия, социально-экономические последствия

Regional wage differentiation in Russia: causes and consequences

CORRESPONDENCE:

Anastasia S. Martiyanova

E-mail: anastasiamartianova2004@yandex.ru

FOR CITATION:

Martiyanova A.S., Baycherova A.R.
Regional wage differentiation in
Russia: causes and consequences.
Global Agricultural Research. 2026;1:5.

Anastasia S. Martiyanova ✉, Angelica R. Baycherova

Stavropol State Agrarian University, Stavropol, Russia

ABSTRACT

The issue of wage differentiation remains a key topic in socio-economic development research. In Russia, this problem is particularly acute due to significant regional inequality, which is among the highest among major global economies. The aim of this study is a comprehensive analysis of the key factors determining wage differentiation across Russian regions and an assessment of their impact on the level of income inequality. The research reveals serious socio-economic consequences of the existing disparity: increased outmigration of skilled labor from economically depressed regions and structural distortions in the national labor market. An analysis of statistical data and existing trends indicates that the established interregional inequality in wages not only persists but also shows a tendency to intensify, despite the ongoing measures of state regulation.

KEYWORDS: salary, average monthly salary, income of the population, regional differences, factors, regional differentiation, intersectoral differences, socio-economic consequences

COPYRIGHT: © 2026 Martiyanova A.S.,
Baycherova A.R.

ВВЕДЕНИЕ

Проблема дифференциации заработной платы остается одной из наиболее актуальных и многогранных в современных социально-экономических исследованиях. В условиях рыночной экономики неравенство в оплате труда, с одной стороны, выполняет стимулирующую функцию, сигнализируя о востребованности тех или иных компетенций, а с другой – является ключевым индикатором социального расслоения и экономической нестабильности в обществе. Современная картина дифференциации заработных плат в России характеризуется сложным переплетением факторов, унаследованных от плановой экономики, и новых тенденций, порожденных рыночными отношениями. Традиционно в фокусе научного сообщества находятся такие детерминанты, как отраслевая и региональная сегментация рынка труда, обусловленная сырьевой ориентацией экономики и значительной пространственной неоднородностью. Целью настоящего исследования является комплексный анализ ключевых факторов дифференциации заработной платы в России и оценка их совместного влияния на уровень доходного неравенства. Для ее достижения важно проанализировать динамику и современную структуру дифференциации оплаты труда в стране на макроуровне.

На сегодняшний день Россия демонстрирует один из самых высоких уровней регионального неравенства в оплате труда среди крупных экономик мира, что представляет собой серьезную проблему для сбалансированного территориального развития страны. Согласно данным Федеральной службы государственной статистики за март 2025 года разрыв между регионами с максимальной и минимальной среднемесячной заработной платой достиг 4,3 раза: в Москве этот показатель составляет 188 977,7 рублей, тогда как в Республике Ингушетия – лишь 44 328,8 рублей, такая значительная дифференциация обусловлена сложным сочетанием экономических, географических и институциональных факторов, анализ которых представляет значительный научный и практический интерес (Таблица 1) [1–3]:

Таблица 1
Среднемесячная заработная плата в субъектах России

Table 1
Average monthly salary in the Russian regions

№ п/п	Субъект РФ	2024	2025 (март)
1.	Москва	162 571,70	188 977,70
2.	Санкт-Петербург	110 473,1	118 565,7
3.	Московская область	99 204,9	110 253,5
4.	Ленинградская область	82 025,8	89 881,4
5.	Тюменская область	81 678,8	89 386,0
6.	Тульская область	73 868,0	80 386,0
7.	Республика Бурятия	72 925,8	78 083,1
8.	Республика Башкортостан	67 587,6	71 600,9
9.	Республика Алтай	63 529,3	66 395,7
10.	Республика Адыгея	56 300,8	60 432,4
11.	Ставропольский край	57 182,7	59 393,2
12.	Орловская область	56 133,5	59 225,3
13.	Ивановская область	49 722,5	53 363,4
14.	Республика Дагестан	44 639,2	47 904,1
15.	Республика Ингушетия	40 587,6	44 328,8

Основной причиной таких региональных различий в заработной плате является специализация и основные отрасли экономики субъекта. В сырьевых регионах, таких как Тюменской и Тульской областях, Ямало-Ненецком АО, Ханты-Мансийском АО, Ненецком АО и иных, доминирующим и основным является добывающий сектор, обеспечивающий высокую добавленную стоимость и зарплаты на 80–120 % выше среднероссийских [4]. Также немаловажную роль играют отрасли обрабатывающего производства, включая машиностроение, химическую промышленность и металлургию, где зарплаты близки к среднему уровню по стране. При этом в аграрных регионах, таких как Ставропольский край, Ивановская и Орловская области, и депрессивных областях Центральной России доходы на 20–40% ниже среднероссийских показателей из-за низкой производительности труда в сельском хозяйстве и легкой промышленности, которые являются основными направлениями таких субъектов. Дефицит инвестиций в модернизацию производств и развитие инфраструктуры, а также слабая дифференциация экономики ограничивают возможности экономического роста [5]. Наглядно такие различия в заработной плате можно рассмотреть в Таблице 2:

Таблица 2

Среднемесячная заработная плата в России по отраслям за 2022–2024 годы

Table 2

Average monthly salary in Russia by industry for 2022–2024

Отрасль	2022	2023	2024	2024 к 2022 в %
Растениеводство и животноводство	41 993,70	48 840,40	59 833,70	142,48
Лесоводство и лесозаготовки	48 327,20	53 542,80	63 792,20	132,00
Добыча нефти и природного газа	165 623,80	180 947,00	217 949,80	131,59
Добыча полезных ископаемых	77 562,00	89 697,30	105 325,90	135,80
Производство химических веществ и продуктов	75 282,50	87 872,90	105 835,00	140,58
Строительство	57 849,20	69 235,20	81 418,70	140,74
Образование	48 400,20	54 314,80	62 914,60	129,99
Деятельность в сфере здравоохранения	57 460,60	63 880,40	74 585,20	129,80

Географическое положение регионов также оказывает существенное влияние на уровень доходов населения [6]. Северные и дальневосточные субъекты традиционно характеризуются повышенными заработными платами благодаря применению районных коэффициентов в диапазоне от 1,5 до 2,0, призванные компенсировать сложные условия труда, тем самым создают дополнительный дисбаланс в оплате труда между регионами. В то же время приграничные и депрессивные районы сталкиваются с проблемой низких доходов, что связано со слабой транспортной инфраструктурой, низким уровнем развития и внедрения новых технологий, недостаточной дифференциацией экономики и ограниченной инвестиционной привлекательностью этих территорий.

Ещё одним важным фактором дифференциации выступает система межбюджетных отношений. Регионы-доноры, в частности Москва, Татарстан и Санкт-Петербург, концентрируют значительные финансовые ресурсы, тогда как дотационные субъекты, особенно на Северном Кавказе, в значительной степени зависят от федеральных трансфертов, что объективно ограничивает возможности роста доходов населения и в целом уровня жизни.

Региональное неравенство в оплате труда порождает ряд серьезных социально-экономических последствий. Наиболее значимым из них является миграционный отток населения из депрессивных регионов в ключевые субъекты страны. Согласно исследованиям ННГУ имени Н. И. Лобачевского, ежегодные потери трудоспособного населения в таких субъектах для России составляют 1,5–2 % от общей численно-

сти [7]. Другим значимым последствием становится неравномерность социально-экономического развития, когда отстающие регионы попадают в «ловушку недоразвития», теряя возможность самостоятельно преодолевать экономическое отставание.

Значительная региональная дифференциация доходов в России представляет собой серьезную системную проблему, оказывающую комплексное негативное воздействие на социально-экономическое развитие страны. Чрезмерный разрыв в уровне заработных плат между регионами приводит к массовой миграции трудоспособного населения из депрессивных территорий, что усугубляет демографические дисбалансы и создает дефицит квалифицированных кадров во многих субъектах [8; 9]. Сложившаяся ситуация вызывает серьезные структурные перекосы на рынке труда и в инвестиционной сфере. Наблюдается перенасыщение трудовыми ресурсами в сырьевых регионах при одновременном их дефиците в других субъектах России, что искажает конкурентную среду и снижает общую эффективность экономики.

Для решения проблемы региональной дифференциации заработной платы требуется комплексный подход, включающий меры как на федеральном, так и на региональном уровнях [10]. Ключевыми направлениями политики доходов могли бы стать совершенствование системы межбюджетного регулирования, развитие специальных экономических зон в отстающих регионах, реализация программ стимулирования внутренней трудовой миграции, а также создание условий для диверсификации региональных экономик. Особое внимание стоит уделить разработке дифференцированных подходов к регулированию минимального размера оплаты труда, так как ее современная система установления по всей территории России не учитывает существенных различий в стоимости жизни между регионами, что значительно снижает эффективность данной меры социальной поддержки. В условиях, когда потребительская корзина в Москве и северных регионах может быть на 40–60 % дороже, чем в центральных и южных областях, единый МРОТ фактически обеспечивает разный уровень социальной защиты в различных субъектах страны. Опыт таких стран, как США (где минимальная зарплата варьируется между штатами) и Китай (с его провинциальными нормативами), показывает эффективность подобного подхода. В российских условиях это особенно актуально для северных территорий с высокой стоимостью жизни и аграрных регионов с низкой производительностью труда.

Таким образом, проведенное исследование региональной дифференциации заработной платы в России выявило устойчивую и глубокую структурную проблему, оказывающую комплексное негативное воздействие на социально-экономическое развитие страны. Анализ статистических данных и существующих тенденций позволяет констатировать, что сложившееся межрегиональное неравенство в оплате труда не только сохраняется, но и имеет тенденцию к усилению, несмотря на предпринимаемые меры государственного регулирования. Основными факторами, способствующими сохранению и углублению региональных диспропорций, выступают: сырьевая ориентация экономики ряда территорий, недостаточная диверсификация производств в аграрных и промышленных регионах, а также сохраняющиеся инфраструктурные ограничения. Для решения ряда проблем необходим комплекс государственных мер, реализация которого позволит не только сократить существующие диспропорции, но и создать условия для более сбалансированного территориального развития страны.

ЗАКЛЮЧЕНИЕ

В статье проведен комплексный анализ проблемы территориальной дифференциации уровня заработной платы в Российской Федерации. Исследование подтвердило, что региональное неравенство в оплате труда представляет собой устойчивую структурную проблему, оказывающую системное негативное воздействие на социально-экономическое развитие страны. Полученные результаты показали, что ключевыми детерминантами сложившегося дисбаланса выступают сырьевая ориентация экономики ведущих регионов, недостаточная диверсификация производств в аграрных и промышленных субъектах, а также сохраняющиеся инфраструктурные и географические ограничения. Установлено, что доминирующий фактор – отраслевая специализация, что наглядно демонстрирует разрыв в доходах между работниками добывающего сектора и сельского хозяйства. Социально-экономические последствия, такие как интен-

сивная миграция трудоспособного населения и усиление территориальных диспропорций, формируют «ловушку недоразвития» для депрессивных регионов, создавая замкнутый круг неравенства. В качестве перспективных направлений для будущих исследований целесообразно выделить углубленный анализ эффективности специальных экономических зон в отстающих регионах, а также моделирование долгосрочных последствий дифференцированной политики доходов на выравнивание пространственного развития и стабилизацию миграционных потоков.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Бюджетный кодекс Российской Федерации от 31.07.1998 № 145-ФЗ [consultant.ru]. КонсультантПлюс; [ред. от 24.09.2023]. URL: <http://www.consultant.ru>
Budget Code of the Russian Federation No. 145-FZ dated July 31, 1998 [consultant.ru]. Consultant-Plus; [ed. dated 09/24/2023]. (In Russ.). URL: <http://www.consultant.ru>
2. Анализ заработных плат по регионам России. Audit-IT. URL: https://www.audit-it.ru/inform/zarplata/index.php?id_region=27
Analysis of salaries by regions of Russia. 1. Audit-IT. (In Russ.). URL: https://www.audit-it.ru/inform/zarplata/index.php?id_region=27
3. Федеральная служба государственной статистики (Росстат). Rosstat. URL: <https://rosstat.gov.ru>
Federal State Statistics Service (Rosstat). URL: <https://rosstat.gov.ru>
4. О минимальном размере оплаты труда : федеральный закон от 19.06.2000 № 82-ФЗ [consultant.ru]. КонсультантПлюс; [ред. от 14.07.2022]. URL: <http://www.consultant.ru>
On the minimum wage: Federal Law No. 82-FZ dated 06/19/2000 [consultant.ru]. ConsultantPlus; [ed. dated 07/14/2022]. (In Russ.). URL: <http://www.consultant.ru>
5. Байчерова А.Р., Бабыкин А.А. Мотивация работников вступления в профсоюз как гарантия защиты их трудовых прав. *Развитие предпринимательства: новые горизонты. Сборник трудов по материалам Международной научно-практической конференции, посвященной Дню российского предпринимательства, 85-летию Ставропольского государственного аграрного университета, 70-летию Победы в Великой Отечественной войне*. Ставрополь. 2015;35-38.
Baicherova A.R., Babykin A.A. Motivation of employees to join a trade union as a guarantee of protection of their labor rights. *Business development: new Horizons, a collection of papers based on the materials of the International Scientific and Practical Conference dedicated to the Day of Russian Entrepreneurship, the 85th anniversary of Stavropol State Agrarian University, the 70th anniversary of victory in the Great Patriotic War*. Stavropol. 2015;35-38. (In Russ.).
6. Гурвич Е.Т. Региональное неравенство в России: причины и последствия. *Вопросы экономики*. 2022;5:45-62.
Gurvich E.T. Regional inequality in Russia: causes and consequences. *Economic Issues*. 2022;5:45-62. (In Russ.).
7. Городнов А.В. Миграционные процессы в контексте социально-демографической ситуации в современной России. *Вестник Нижегородского университета им. Н. И. Лобачевского. Серия: Социальные науки*. 2022;4(68):142-153. https://doi.org/10.52452/18115942_2022_4_142
Gorodnov A.V. Migration processes in the context of the socio-demographic situation in modern Russia. *Bulletin of the Nizhny Novgorod Lobachevsky University. Series: Social Sciences*. 2022;4(68):142-153. (In Russ.). https://doi.org/10.52452/18115942_2022_4_142
8. Козел И.В., Байчерова А.Р. *Экономика труда*. Курс лекций в 2-х частях. Ставрополь. 2013. Часть 2.
Kozel I.V., Baicherova A.R. *Labor economics*. A course of lectures in 2 parts. Stavropol. 2013. Part 2. (In Russ.).
9. Ivashova V.A., Bulankina N.N., Baicherova A.R., Maslova L.F., Skrebtsova T.V. Factors of satisfaction with wages of employees of enterprises of Stavropol territory. *International Journal of Engineering and Technology*. 2018;7(4.38):224-227.

10. Дауров Г.Э., Джюева М.А. Проблема территориальной дифференциации уровня зарплат в России (на примере СКФО, ЦФО и СФО). *Бюллетень Владикавказского института управления*. 2024;(68):357-369.

Daurov G.E., Dzhioeva M.A. The problem of territorial differentiation of the salary level in Russia (on the example of the North Caucasus Federal District, Central Federal District and SFO). *Bulletin of the Vladikavkaz Institute of Management*. 2024;(68):357-369. (In Russ.).

Сведения об авторах

Мартянова Анастасия Сергеевна –

студентка, 3 курс, направление «Экономика предприятий и организаций», Ставропольский государственный аграрный университет, Ставрополь, Россия

<https://orcid.org/0009-0001-5952-5632>

anastasiamartianova2004@yandex.ru

Байчерова Анжелика Рашитовна –

кандидат экономических наук, доцент, Ставропольский государственный аграрный университет, Ставрополь, Россия

<https://orcid.org/0000-0003-0754-9701>

SPIN-код: 9429-7383

corsta@mail.ru

About the authors

Anastasia S. Martyanova –

3rd year student, Economics, Economics of Enterprises and Organizations, Stavropol State Agrarian University, Stavropol, Russia

<https://orcid.org/0009-0001-5952-5632>

anastasiamartianova2004@yandex.ru

Angelica R. Baycherova –

Candidate of Economic Sciences, Associate Professor, Stavropol State Agrarian University, Stavropol, Russia

<https://orcid.org/0000-0003-0754-9701>

corsta@mail.ru

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

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 Vazifiedoust 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 натуры 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. Lepikhina –

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

Информационно-измерительная система для исследования почвенного гальванического элемента

КОРРЕСПОНДЕНЦИЯ:**Руслан Сергеевич Жилин**

E-mail: Zhilinuslan228@gmail.com

ДЛЯ ЦИТИРОВАНИЯ:

Жилин Р.С., Вострухин А.В.
Информационно-измерительная
система для исследования
почвенного гальванического
элемента. *Global Agricultural
Research*. 2026;1:7.

Р.С. Жилин ✉, А.В. Вострухин

Ставропольский государственный аграрный университет, Ставрополь, Россия

АННОТАЦИЯ

На базе платформы Arduino разработана информационно-измерительная система, предназначенная для выполнения экспериментальных исследований почвенного гальванического элемента (ПГЭ). ПГЭ предназначен для построения энергохарвестеров – источников питания беспроводных подземных датчиков климата почвы. Экспериментальная информационно-измерительная система построена с использованием микроконтроллерного устройства Arduino nano и дополнительного оборудования с целью исследования зависимости выходных электрических характеристик ПГЭ от изменяющихся во времени физических величин, температуры и влажности различных типов почв. Разработана электронная схема, включающая: гальваническую пару Cu-Zn, нагрузочный резистор, датчик влажности почвы LM393 и температурный датчик DS18B20. Информационно-измерительная система позволяет осуществлять измерение напряжения, тока и расчёт внутреннего сопротивления ПГЭ в динамике. Полученные результаты могут быть использованы при разработке автономных систем экологического мониторинга и климата почвы для повышения эффективности систем управления орошением и плодородия почв в сельском хозяйстве.

КЛЮЧЕВЫЕ СЛОВА: микроконтроллер, программное обеспечение, почвенный гальванический элемент, влажность почвы, внутреннее сопротивление, Arduino nano, беспроводной датчик

Information-measurement system for the study of a soil galvanic element

CORRESPONDENCE:**Ruslan S. Zhilin**

E-mail: Zhilinruslan228@gmail.com

FOR CITATION:

Zhilin R.S., Vostrukhin A.V.

Information-measurement system for the study of a soil galvanic element. *Global Agricultural Research*. 2026;1:7

Ruslan S. Zhilin ✉, Alexander V. Vostrukhin

Stavropol State Agrarian University, Stavropol, Russia

ABSTRACT

An information and measurement system based on the Arduino platform has been developed for conducting experimental studies of a soil galvanic cell (SGC). The SGC is intended for building energy harvesters – power sources for wireless underground soil climate sensors. The experimental information and measurement system is built using the Arduino nano microcontroller device and additional equipment to study the dependence of the output electrical characteristics of the SGC on time-varying physical quantities, temperature and humidity of different soil types. An electronic circuit has been developed, including: a Cu-Zn galvanic pair, a load resistor, an LM393 soil moisture sensor and a DS18B20 temperature sensor. The information and measurement system allows for the measurement of voltage, current and calculation of the internal resistance of the SGC in real-time. The obtained results can be used in the development of autonomous environmental and soil climate monitoring systems to improve the efficiency of irrigation management and soil fertility systems in agriculture.

KEYWORDS: microcontroller, software, soil galvanic cell, soil moisture, internal resistance, Arduino nano, wireless sensor

ВВЕДЕНИЕ

Интернет подземных вещей (IoUT) и беспроводные подземные сенсорные сети (WUSN) – это новые технологии, особенно актуальные в сельском хозяйстве для измерения и передачи данных об окружающей среде, что позволяет оптимизировать как рост сельскохозяйственных культур, так и управление водными ресурсами [1]. Сенсорные узлы могут быть закопаны в любом месте, в том числе при проезде транспортных средств, не мешая надземной сельскохозяйственной деятельности [2]. Одной из научно-технических проблем является обеспечение сенсорных систем автономными источниками питания, работающими под пахотным слоем земли. В настоящей работе предлагается решение – использовать почвенный гальванический элемент (ПГЭ), представляющий собой автономный источник низкого напряжения, формируемого за счет электрохимического взаимодействия пары разнородных металлов, помещенных в почву, играющую роль естественного электролита. Аналогичные принципы получения электрической энергии из почвенной среды широко рассматриваются в исследованиях по микробным и почвенным гальваническим элементам, где почва выступает электролитом, а разнородные электроды формируют устойчивую электрохимическую пару [3]. Значение внутреннего сопротивления ПГЭ, а также ток, который элемент способен отдавать в нагрузку, зависят от параметров среды – прежде всего от влажности и температуры почвы [4]. При увеличении влажности концентрация свободных ионов возрастает, улучшается электрическая проводимость грунта и, соответственно, снижается внутреннее сопротивление ПГЭ [5]. Электропроводность почвы и, как следствие, электрические характеристики почвенных гальванических элементов существенно зависят от влажности, температуры и ионного состава порового раствора, что подтверждено в фундаментальных исследованиях почвенной электропроводности [6]. Исследование этой зависимости представляет интерес для разработки автономных низкопотребляющих систем мониторинга состояния почвы, датчиков влажности, экологических систем питания и других устройств, работающих без внешнего источника энергии [7].

Целью работы является создание информационно-измерительной системы для измерения и регистрации электрических величин ПГЭ – напряжения холостого хода и тока короткого замыкания, а также влажности и температуры почвы.

МАТЕРИАЛЫ И МЕТОДЫ

Аппаратное обеспечение информационно-измерительной системы

Для реализации информационно-измерительной системы использовалась микроконтроллерная платформа Arduino nano, позволяющая одновременно измерять несколько параметров, фильтровать сигнал и осуществлять запись данных через последовательный интерфейс. Платформа Arduino широко применяется при создании экспериментальных информационно-измерительных систем благодаря открытой архитектуре, наличию встроенного АЦП и большому количеству готовых библиотек, что делает ее удобным инструментом для научных исследований и прототипирования [8]. На рисунке 1 представлена принципиальная электрическая схема информационно-измерительной системы, предназначенной для исследования электрических характеристик почвенного гальванического элемента (ПГЭ). Схема разработана в среде EasyEDA и включает в себя микроконтроллер Arduino Nano, гальваническую пару электродов Cu–Zn, нагрузочный резистор R1, цифровой температурный датчик DS18B20, датчик влажности почвы типа LM393, а также цепи фильтрации питания.

Гальванический элемент и измерение его параметров

В качестве ПГЭ используется пара разнородных электродов – медный электрод Cu⁺ (P1) и цинковый электрод Zn[–] (P2). Цинковый электрод соединен с шиной общей земли (GND), которая является опорным потенциалом для всех измерений. Медный электрод подключен к узлу измерения напряжения, который подводится на аналоговый вход A0 микроконтроллера Arduino Nano. Для возможности измерения как ЭДС холостого хода, так и напряжения под нагрузкой в схеме применяется нагрузочный резистор R1 сопротивлением 100 Ом. Один его вывод подключен к узлу измерения (между Cu и A0),

а второй – к цифровому выходу D3 Arduino Nano. Такой способ подключения позволяет программно подключать и отключать нагрузку: при переводе вывода D3 в режим INPUT резистор отключен (режим холостого хода); при установке вывода D3 в состояние OUTPUT LOW нагрузка подключается к земле. Такой метод исключает необходимость использования дополнительных транзисторов и обеспечивает безопасный ток (менее 5 мА), при этом позволяя реализовать оба режима измерения электрических величин ПГЭ [9].




Рисунок 1

Принципиальная схема информационно-измерительной системы для исследования почвенного гальванического элемента

Figure 1

Schematic diagram of the information and measurement system for studying a soil galvanic cell

Измерение температуры почвы

В схему, представленную на Рисунок 1, включен цифровой температурный датчик DS18B20, работающий по интерфейсу 1-Wire. Вывод DQ соединен с цифровым пином D2 Arduino Nano. Линия данных подтянута к шине питания VCC через резистор 4,7 кОм (R2), что является обязательным условием корректной работы по интерфейсу OneWire.

Измерение влажности почвы

Для измерения влажности используется датчик из платы усилителя LM393 (Рисунок 2). Конструктивно датчик состоит из платы усилителя сигнала на LM393 и выносного датчика с двумя токопроводящими длинными контактами, которые погружаются в почву. Принцип работы датчика основан на измерении электрического сопротивления между погруженными в почву контактами, которое изменяется при увлажнении почвы. Сигнальный вывод датчика SIG подключен к аналоговому входу A2, что позволяет регистрировать уровень влажности почвы в диапазоне 0...100 %. Питание модуля осуществляется от шины +5 В (VCC), общая земля датчика связана с землей схемы.



Рисунок 2
Датчик влажности почвы

Figure 2
Soil moisture sensor

Элементы фильтрации

Для снижения цифровых и коммутационных помех на линии питания установлены: керамический конденсатор $C1 = 100$ нФ, электролитический конденсатор $C2 = 10$ мкФ. Они обеспечивают локальную фильтрацию высокого и среднего диапазона частот, что улучшает точность измерений аналоговых сигналов.

Микроконтроллерная система Arduino Nano выполняет следующие функции:

- измерение напряжения ПГЭ, аналоговый вход (A0);
- измерение влажности, аналоговый вход (A2);
- управление нагрузкой ПГЭ, цифровой выход (D3);
- обмен с датчиком DS18B20 (D2);
- передача данных через UART-интерфейс.

Программное обеспечение информационно-измерительной системы

Для реализации работы информационно-измерительной системы разработана программа на языке C/C++ для микроконтроллерной платформы Arduino Nano. В начале программы осуществляются подключения необходимых библиотек, объявление используемых пинов микроконтроллера, а также инициализация датчиков. В данном фрагменте задаются основные параметры системы: номера входов и выходов Arduino, сопротивление нагрузочного резистора, количество усреднений для уменьшения шумов АЦП и опорное напряжение для пересчета значений АЦП в физические величины. Ниже представлен фрагмент исходного кода (Рисунок 3), определяющий структуру программы и базовые параметры информационно-измерительной системы.

```
1  #include <OneWire.h>
2  #include <DallasTemperature.h>
3
4  // --- Конфигурация пинов ---
5  const int PIN_PGE = A0;      // Узел Cu
6  const int PIN_LOAD = 3;      // Нагрузочный резистор R1
7  const int PIN_SOIL = A2;     // Датчик влажности почвы
8  const int PIN_TEMP = 4;     // DS18B20 data line
9
10 // --- Инициализация датчиков ---
11 OneWire oneWire(PIN_TEMP);
12 DallasTemperature sensors(&oneWire);
13
14 // --- Калибровочные константы ---
15 const float R_LOAD = 100.0;  // Сопротивление нагрузочного резистора (Ом)
16 const float V_REF = 5.0;     // Опорное напряжение АЦП (В)
17 const int NUM_SAMPLES = 10;  // Количество усредняемых samples
```

Рисунок 3
Модуль сбора данных о влажности и температуре почвы

Figure 3
Module for collecting data on soil moisture and temperature

На Рисунке 4 функция выполняет несколько последовательных измерений с аналогового входа, что позволяет уменьшить шум и получить более стабильное значение напряжения.

При отключенной нагрузке пин D3 переводится в режим высокоимпедансного входа, что соответствует холостому ходу ПГЭ (Рисунок 5).

При подключении нагрузочного резистора ($R1 = 100 \text{ Ом}$) клемма D3 замыкает резистор на землю, и система измеряет напряжение под нагрузкой (Рисунок 6).

```
19 float readADCavg(int pin) {
20     const int samples = 10;
21     long sum = 0;
22     for (int i = 0; i < samples; i++) {
23         sum += analogRead(pin);
24         delay(5);
25     }
26     return (float)sum / samples;
27 }
```

Рисунок 4

Модуль кода усредненного измерения напряжения

Figure 4

Average voltage measurement code module

```
29 float measureE(int pinPGE, int pinLoad, float Vref) {
30     pinMode(pinLoad, INPUT); // нагрузка отключена
31     delay(50);
32     float adcVal = readADCavg(pinPGE);
33     return adcVal * (Vref / 1023.0);
34 }
```

Рисунок 5

Модуль кода измерения ЭДС почвенного гальванического элемента

Figure 5

Module of the EMF measurement code of a soil galvanic cell

```
36 float measureVload(int pinPGE, int pinLoad, float Vref) {
37     pinMode(pinLoad, OUTPUT);
38     digitalWrite(pinLoad, LOW); // подключение R1 к земле
39     delay(50);
40     float adcVal = readADCavg(pinPGE);
41     pinMode(pinLoad, INPUT); // возвращаем холостой ход
42     return adcVal * (Vref / 1023.0);
43 }
```

Рисунок 6

Модуль кода измерения напряжения под нагрузкой

Figure 6

Voltage measurement code module under load

На основе закона Ома вычисляются:

- ток через нагрузку;
- внутреннее сопротивление гальванического элемента (Рисунок 7).

```
45 void calculateParameters(float E, float V, float Rload, float &I, float &Rint) {
46     I = V / Rload;
47     if (I > 0.0000001) {
48         Rint = (E - V) / I;
49     } else {
50         Rint = 0;
51     }
52 }
```

Рисунок 7

Модуль кода расчета тока и внутреннего сопротивления

Figure 7

Current and internal resistance calculation code module

Основной цикл последовательно вызывает все модули: считывает ЭДС, напряжение под нагрузкой, влажность, температуру и выводит результаты в последовательный порт (Рисунок 8).

Программная часть модели выполняет несколько ключевых функций: считывание параметров влажности, измерение напряжения на нагрузочном резисторе, преобразование показаний АЦП в электрические величины и вычисление тока по закону Ома. Влажность почвы определяется на основе функции `map()`, переводящей диапазон АЦП 0–1023 в проценты влажности 0–100 %. Для измерения напряжения ПГЭ выполняется чтение входа A0, а значение АЦП переводится в милливольты через коэффициент 4,88 (чувствительность одного шага преобразования при опорном напряжении 5 В). Зная напряжение и сопротивление резистора R1, ток вычисляется по формуле $I = V / R1$.

Полученные данные выводятся в последовательный порт, что позволяет фиксировать зависимость тока от влажности почвы. На основе этих данных в дальнейшем можно рассчитать внутреннее сопротивление ПГЭ по выражению $R_{\text{внутр}} = (E - V) / I$ где E – ЭДС гальванического элемента, определяемая в отдельном измерении без нагрузки.

```
54 void loop() {
55     float E = measureE(A0, 3, 5.0);    // ЭДС
56     float Vload = measureVload(A0, 3, 5.0); // Напряжение под нагрузкой
57
58     float I, Rint;
59     calculateParameters(E, Vload, 1000.0, I, Rint);
60
61     // Датчик DS18B20
62     sensors.requestTemperatures();
63     float tempC = sensors.getTempCByIndex(0);
64
65     // Влажность почвы
66     int soilRaw = analogRead(A2);
67     int soilPercent = map(soilRaw, 0, 1023, 0, 100);
68
69     // Вывод
70     Serial.println("=====");
71     Serial.print("E (мВ): ");
72     Serial.println(E * 1000);
73     Serial.print("V (мВ): ");
74     Serial.println(Vload * 1000);
75     Serial.print("I (мА): ");
76     Serial.println(I * 1000);
77     Serial.print("Rвнутр (Ом): ");
78     Serial.println(Rint);
79     Serial.print("Влажность (%): ");
80     Serial.println(soilPercent);
81     Serial.print("Температура (°C): ");
82     Serial.println(tempC);
83     Serial.println();
84
85     delay(1000);
86 }
```

Рисунок 8

Модуль кода основного цикла информационно-измерительной системы

Figure 8

Module of the main cycle code of the information-measuring system

ЗАКЛЮЧЕНИЕ

Таким образом, совмещенная электронная схема и программный модуль образуют полнофункциональную модель измерения почвенного гальванического элемента. Они позволяют изучать изменение его электрических характеристик в зависимости от влажности среды, что является основой для построения теоретической зависимости внутреннего сопротивления ПГЭ от влажности, а также оценки возможности практического применения таких элементов в автономных системах мониторинга состояния почвы.

Разработанная электронная схема и программный модуль Arduino Nano позволяют осуществлять комплексное измерение параметров почвенного гальванического элемента, включая напряжение, влажность почвы и ток через нагрузку. Модель обеспечивает возможность наблюдения за изменением электрических характеристик ПГЭ в условиях изменяющейся влажности, что делает ее подходящим инструментом для учебных и исследовательских задач. Полученные данные позволяют оценить поведение гальванического элемента в реальных условиях эксплуатации и подтверждают возможность использования подобных систем в автономных датчиках и экологических мониторинговых установках.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Жилин Р.С. Современные технологии энергохарвестинга для систем питания подземных беспроводных датчиков климата почвы. *Современные проблемы АПК: сборник научных статей Института механики и энергетики 90-й научно-практической конференции «Аграрная наука – Северо-Кавказскому федеральному округу», г. Ставрополь, 6 мая 2025 г.* Ставрополь. 2025:383.
Zhilin R.S. Modern energy harvesting technologies for power supply systems for underground wireless soil climate sensors. *Modern Problems of agriculture: collection of scientific articles of the Institute of Mechanics and Power Engineering, dedicated to the 90th scientific and practical conference «Agrarian Science to the North Caucasus Federal District», Stavropol, May 6, 2025.* Stavropol. 2025:383. (In Russ.).
2. Cariou C., Moiroux-Arvis L., Pinet F., Chanet J.P. Internet of Underground Things in Agriculture 4.0: Challenges, Applications and Perspectives. *Sensors*. 2023;23:40-58. <https://doi.org/10.3390/s23084058>
3. Logan B.E., Hamelers B., Rozendal R. et al. Microbial fuel cells: methodology and technology. *Environmental Science and Technology*. 2006;40(17):5181-5192. <https://doi.org/10.1021/es0605016>
4. Тимофеев Н.Н., Абакумов Е.В. *Лабораторные работы по почвоведению : метод. указания для студентов 2 курса по направлению подготовки 35.03.03 «Агрохимия и агропочвоведение» / Министерство сельского хозяйства РФ, Ивановская ГСХА. Иваново. 2018;51.*
Timofeev N.N., Abakumov E.V. *Laboratory work on soil science : method. instructions for 2nd year students in the field of training 03.35.03 «Agrochemistry and agro soil science» / Ministry of Agriculture of the Russian Federation, Ivanovo Agricultural Academy. Ivanovo. 2018;51. (In Russ.).*
5. Околелова А.А., Желтобрюхов В.Ф., Егорова Г.С. и др. *Применение гидрогеля в почвах.* Волгоградский государственный аграрный университет. 2016;104.
Okolelova A.A., Zheltobryukhov V.F., Egorova G.S. et al. *The use of hydrogel in soils.* Volgograd State Agrarian University. 2016;104. (In Russ.).
6. Rhoades J.D., Manteghi N.A., Shouse P.J., Alves W.J. Soil electrical conductivity and soil salinity: New formulations and calibrations. *Soil Science Society of America Journal*. 1989; 53(2):433-439.
7. Paradiso J.A., Starner T. Energy scavenging for mobile and wireless electronics. *IEEE Pervasive Computing*. 2005;4(1):18-27. <https://doi.org/10.1109/MPRV.2005.9>
8. Banzi M., Shiloh M. *Getting Started with Arduino*. 3rd ed. Sebastopol: O'Reilly Media, 2014;130 p.
9. Arduino Nano: на базе микроконтроллера «ATmega328PB» [iarduino.ru.]. Iarduino; 2024. URL: <https://wiki.iarduino.ru/page/arduino-nano-atmega328pb/>

- Arduino Nano: based on the «ATmega328PB» microcontroller [iarduino.ru.]. Iarduino; 2024. (In Russ.). URL: <https://wiki.iarduino.ru/page/arduino-nano-atmega328pb/>
10. Вострухин А.В., Мастепаненко М.А., Вахтина Е.А. Энергосберегающий асинхронный интерфейс для беспроводных датчиков. *Вестник Томского государственного университета. Управление, вычислительная техника и информатика*. 2023;63:92-102. <https://doi.org/10.17223/19988605/63/11>
- Vostrukhin A.V., Mastepanenko M.A., Vakhtina E.A. Energy-saving asynchronous interface for wireless sensors. *Bulletin of Tomsk State University. Management, Computer Engineering and Computer Science*. 2023;63:92-102. (In Russ.). <https://doi.org/10.17223/19988605/63/11>

Сведения об авторах

Жилин Руслан Сергеевич –

студент, 2 курс, направление «Электроэнергетика и электротехника», Ставропольский государственный аграрный университет, Ставрополь, Россия

<https://orcid.org/0009-0001-4496-0914>

zhilinruslan228@gmail.com

Вострухин Александр Витальевич

научный руководитель, кандидат технических наук, доцент, научный сотрудник кафедры электротехники, автоматики и метрологии Ставропольский государственный аграрный университет, Ставрополь, Россия

<https://orcid.org/0000-0002-2310-2339>

SPIN-код: 7414-7478

avostrukhin@yandex.ru

About the authors

Ruslan S. Zhilin –

2nd year student, Power Engineering and Electrical Engineering, Stavropol State Agrarian University, Stavropol, Russia

<https://orcid.org/0009-0001-4496-0914>

zhilinruslan228@gmail.com

Alexander V. Vostrukhin –

Scientific Supervisor, Candidate of Technical Sciences, Associate Professor, Researcher at the Department of Electrical Engineering, Automation and Metrology, Stavropol State Agrarian University, Stavropol, Russia

<https://orcid.org/0000-0002-2310-2339>

avostrukhin@yandex.ru