

Большие языковые модели (LLM): новый этап цифровой трансформации агропромышленного комплекса России

Д. М. Назаров[✉], С. В. Бегичева, А. А. Копнин

Уральский государственный экономический университет, Екатеринбург, Россия

[✉]E-mail: slup2005@mail.ru

Аннотация. Статья посвящена исследованию интеграции больших языковых моделей (LLM) в российский агропромышленный комплекс (АПК). Авторы ставят задачу рассмотреть основные аспекты внедрения данной технологии, подчеркнув ее актуальность в условиях цифровой трансформации. **Целью** работы является всесторонний анализ применения LLM-моделей для решения ключевых задач в сельском хозяйстве. **Методы.** Методологической основой служат системный подход, методы анализа научной литературы и кейс-стади, в рамках которых исследуется возможность реализации предложенных технологий искусственного интеллекта (ИИ) в контексте конкретного объекта сельского хозяйства. **Научная новизна** данного исследования заключается в комплексном рассмотрении использования LLM-моделей для сельского хозяйства России, при этом учитываются локальные инфраструктурные особенности, дается карта технической реализации конкретного проекта и разрабатывается модель его окупаемости. Важной частью исследования является оценка экономических показателей, которая позволяет определить сроки окупаемости инвестиций и выявить ключевые факторы риска. **Результаты** показывают, что при увеличении урожайности на 10 % и сокращении затрат на пестициды система окупается уже в течение 1–2 сезонов. Также в рамках построения технологической карты проекта дополнительно выявлены факторы, влияющие на успешность внедрения: обеспечение качественного набора данных, доступ к вычислительным ресурсам и наличие экспертной поддержки. Таким образом, работа демонстрирует значительный потенциал больших языковых моделей в повышении производительности и конкурентоспособности российского АПК и обосновывает целесообразность дальнейших исследований в данном направлении. Также в статье представлены рекомендации по дальнейшему совершенствованию и адаптации LLM-моделей, которые в ближайшем будущем могут обеспечить устойчивое развитие отечественного аграрного сектора.

Ключевые слова: большие языковые модели (LLM), искусственный интеллект (ИИ), агропромышленный комплекс (АПК), сельское хозяйство умная ферма, цифровая трансформация, интернет вещей (IoT), экономическая эффективность

Благодарности. Авторы выражают благодарность Российскому научному фонду за поддержку данного исследования в рамках гранта 25-28-01634 «Интеллектуальная система управления цепочками стоимости в агропромышленном комплексе на основе технологий больших данных и искусственного интеллекта».

Для цитирования: Назаров Д. М., Бегичева С. В., Копнин А. А. Большие языковые модели (LLM): новый этап цифровой трансформации агропромышленного комплекса России // Аграрный вестник Урала. 2025. Т. 25, № 07. С. 1129–1142. <https://doi.org/10.32417/1997-4868-2025-25-07-1129-1142>.

Дата поступления статьи: 06.02.2025, **дата рецензирования:** 20.03.2025, **дата принятия:** 07.04.2025.

Large language models (LLM): a new stage of digital transformation of the Russian agro-industrial complex

D. M. Nazarov✉, S. V. Begicheva, A. A. Kopnin

Ural State University of Economics, Ekaterinburg, Russia

✉E-mail: slup2005@mail.ru

ЭКОНОМИКА

Abstract. The article is devoted to the study of the integration of large language models (LLM) into the Russian agro-industrial complex (AIC). The authors set the task of considering the main aspects of the implementation of this technology, emphasizing its relevance in the context of digital transformation. **The purpose** of the work is a comprehensive analysis of the use of LLM models to solve key problems in agriculture. **Methods.** The methodological basis is a systems approach, methods of analyzing scientific literature and case studies, within the framework of which the possibility of implementing the proposed artificial intelligence (AI) technologies in the context of a specific agricultural object is studied. **The scientific novelty** of this study lies in the comprehensive consideration of the use of LLM models for Russian agriculture, taking into account local infrastructure features and providing a map of the technical implementation of a specific project and developing a payback model. An important part of the study is the assessment of economic indicators, which allows us to determine the payback period of investments and identify key risk factors. **The results** show that with a 10 % increase in yield and a reduction in pesticide costs, the system pays off within one or two seasons. Also, as part of constructing a process map of the project, factors influencing the success of implementation were additionally identified: ensuring a high-quality data set, access to computing resources and the availability of expert support. Thus, the work demonstrates the significant potential of large language models in increasing the productivity and competitiveness of the Russian agro-industrial complex and substantiates the feasibility of further research in this area. The article also presents recommendations for further improvement and adaptation of LLM models, which in the near future can ensure sustainable development of the domestic agricultural sector.

Keywords: Large Language Models (LLM), Artificial Intelligence (AI), Agro-Industrial Complex (AIC), agriculture, smart farm, digital transformation, Internet of Things (IoT), economic efficiency

Acknowledgments. The authors express their gratitude to the Russian Science Foundation for supporting this research under grant 25-28-01634 “Intelligent value chain management system in the agro-industrial complex based on big data and artificial intelligence technologies”.

For citation: Nazarov D. M., Begicheva S. V., Kopnin A. A. Large Language Models (LLM): a new stage of digital transformation of the Russian agro-industrial complex. *Agrarian Bulletin of the Urals*. 2025; 25 (07): 1129–1142. <https://doi.org/10.32417/1997-4868-2025-25-07-1129-1142>. (In Russ.)

Date of paper submission: 06.02.2025, **date of review:** 20.03.2025, **date of acceptance:** 07.04.2025.

Постановка проблемы (Introduction)

Современный мир сталкивается с серьезными изменениями, происходящими в сфере сельского хозяйства, которые связаны с ростом населения, обеспечением продовольственной безопасности и увеличивающимся потреблением природных ресурсов: земельных, водных и энергетических. В этих условиях всем предприятиям сельскохозяйственного сектора – от небольших фермерских хозяйств до крупных агрохолдингов – требуется повысить эффективность производства, снизить затраты и сохранять при этом экологический баланс. В контексте четвертой промышленной революции (Industry 4.0) и цифровой трансформации широкое распространение получает так называемый интернет вещей (IoT), а в агропромышленном комплексе

в мировом масштабе формируется концепция smart, или умной, фермы. Под этой концепцией понимают комплекс программно-аппаратных систем, которые через сеть сенсоров, роботов, дронов и компьютерных алгоритмов помогают фермерам повышать эффективность хозяйственной деятельности и принимать более сбалансированные решения в реальном режиме времени. Одним из важнейших элементов такой концепции «умной фермы» становятся инструменты искусственного интеллекта (AI), к числу которых относятся и большие языковые модели (LLM – Large Language Models).

Имеющиеся научные исследования охватывают широкий спектр вопросов по применению искусственного интеллекта (ИИ) и методам машинного обучения в сельском хозяйстве (от общего подхода

до конкретных алгоритмов для прогнозирования и классификации).

В работах F. Shaikh, M. Memon, N. Mahoto, S. Zeadally, J. Nebhen и др. обобщаются лучшие практики использования ИИ в умном сельском хозяйстве, включая мониторинг условий выращивания и автоматизацию производственных процессов в широком смысле, а также рассматриваются вопросы совместимости технологий, их масштабирования с учетом обеспечения безопасности обработки и хранения данных [10].

Применение алгоритмов машинного обучения для классификации и прогнозирования рассматриваются в работах отечественных и зарубежных авторов. В частности, Р. В. Файзуллин и О. А. Новикова [16] провели исследование, посвященное разработке и сравнительному анализу моделей машинного обучения для прогноза урожайности и оптимизации агротехнологических процессов в российских реалиях. Зарубежные ученые R. Gandhi, A. Chellam, T. Prabhu, C. Kathirvel, M. Sivaramkrishnan, S. Ramkumar, E. Elbasi, N. Mostafa, C. Zaki, Z. Al-Arnaout и ряд других рассматривают различные алгоритмы машинного обучения (нейронные сети, решающие деревья и др.) в рамках их применения для классификации болезней растений и оптимизации процесса орошения. Авторы приводят результаты различных экспериментов, показывающих рост продуктивности и снижение затрат в хозяйственной деятельности агропромышленных предприятий благодаря ее планомерной интеллектуализации [3; 4]. Y. S. Klair, K. Agrawal, A. Kumar исследуют применение генеративных алгоритмов для автоматического выявления болезней сельскохозяйственных культур на основе анализа их изображений и проводят сравнительный анализ точности и быстродействия различных архитектур таких систем в полевых условиях [5].

Начиная с 2022 года набирают обороты исследования, связанные с использованием больших языковых моделей (LLM) для поддержки самых разных задач в агропромышленном комплексе – от мониторинга культур до взаимодействия с фермерскими сообществами. В этом направлении научного поиска пока активно работают только зарубежные специалисты. Например, в статье A. Chebbi, G. Kniesel, N. Abdennadher, G. Dimarzo рассматривается разработка систем распознавания сущностей (характеристик) сельскохозяйственных товаров с использованием больших языковых моделей на основе использования ключевых терминов в текстах, связанных с торговлей и логистикой [1]. Интересный аспект, связанный с применением генеративного искусственного интеллекта в управлении цепочками создания стоимости, рассматривается в статье немецкого ученого С. Krupitzer. Автор сосредотачивает свое внимание на исследовании и оптимизации

процессов интеграции ИИ-решений на основе LLM в агропромышленный комплекс [6].

В данной статье мы рассмотрим возможные варианты интеграции больших языковых моделей (LLM) в сельскохозяйственные процессы в России и попытаемся закрыть возникший пробел в исследованиях российских ученых в этом контексте.

Цель статьи – рассмотреть комплексное применение LLM (больших языковых моделей) в агропромышленном комплексе Российской Федерации, привести конкретный пример использования этих моделей и обозначить перспективы развития умного сельского хозяйства на ближайшее время с учетом дальнейшего развития искусственного интеллекта.

Статья состоит из пяти разделов. В первом разделе рассматривается сущность использования LLM в агропромышленном комплексе. Второй раздел посвящен методологии сбора и анализа данных. Третий раздел описывает практическое использование LLM в сельском хозяйстве. В четвертом разделе проведен анализ региональной специфики внедрения LLM в сельском хозяйстве России с учетом оценки рисков. В пятом разделе представлены перспективы развития сельского хозяйства в России в разрезе использования технологий искусственного интеллекта.

Сущность использования LLM в агропромышленном комплексе

Большие языковые модели (LLM, или Large Language Models) – это класс нейронных сетей, обученных на огромных объемах текстовых данных и способных обрабатывать и генерировать новый осмысленный текст основе входного фрагмента текста. В основе Large Language Models лежит архитектура трансформеров (Transformers), предложенная в 2017 году в работе Attention is all you need. Ключевым элементом этой архитектуры является механизм внимания (attention), позволяющий модели выявлять наиболее значимые фрагменты входного текста, чтобы осмысленно (как человек) обрабатывать достаточно длинные последовательности слов [15].

Во время обучения LLM система последовательно получает фрагменты текста (часто это наборы слов) и пытается угадать, какое слово (или, как говорят ИТ-специалисты, токен) следует за уже видимым набором. Ошибки, допущенные в процессе обучения, используются для корректировки весов (параметров) модели по методу обратного распространения ошибки (backpropagation). По мере роста числа параметров (у современных моделей оно может достигать десятков и сотен миллиардов) растет и ее способность модели понимать контекст, а также формировать связные ответы, имитируя мыслительную деятельность человека.

Таблица 1

Обзор статей о применении LLM в сельском хозяйстве

ЭКОНОМИКА

№	Авторы, год	Краткое описание
1	A. Chebbi, G. Kniesel, N. Abdennadher, G. Dimarzo (2024) [1]	В данной работе представлен метод распознавания сущностей, применяемый к текстовым данным о сельскохозяйственных товарах с использованием больших языковых моделей. Предложенное решение повышает точность определения ключевых терминов, встречающихся в материалах, связанных с торговлей и логистикой в агропромышленном секторе
2	C. Dhavale, T. Pawar, A. Singh, S. Pole, K. Sabat (2024) [2]	В этой работе авторы объединили GAN-модели для улучшения качества изображений, CNN для обнаружения болезней растений и LLM как интеллектуального помощника для фермеров. Такое комплексное решение облегчает диагностику и повышает компетенции специалистов в сфере сельского хозяйства
3	V. Madaan, G. Bindal, S. Singh, S. K. Yadav, A. Singh, P. Sinha, et al. (2023) [7]	Авторы разработали гибридную систему, в которой большие языковые модели взаимодействуют с модулями машинного обучения для точной диагностики заболеваний сельскохозяйственных культур. В статье предлагаются практические сценарии применения – от консультации агрономов до формирования автоматизированных рекомендаций, что упрощает процесс принятия решений в полевых условиях конкретной фермы и сельскохозяйственного предприятия
4	S. Stoyanov, M. Kumurdjieva, V. Tabakova-Komsalova, L. Doukowska (2023) [11]	Исследование описывает концепцию умных киберфизических систем в сельском хозяйстве, управляемых большими языковыми моделями. Внедрение подобных систем призвано улучшить координацию, управление ресурсами и масштабируемость решений для различных агротехнических задач
5	J. Qing, X. Deng, Y. Lan, Z. Li (2023) [8]	Работа демонстрирует, как GPT-модель может дополнять возможности компьютерного зрения при диагностике заболеваний растений на изображениях. Авторы совмещают легкий YOLO-алгоритм с генеративным текстовым описанием, чтобы формировать рекомендации и выводы для предприятий агросектора
6	S. Selva Kumar, A. K. M. A. Khan, I. A. Banday, M. Gada, V. V. Shanbhag (2024) [9]	В статье предложен подход Retrieval-Augmented Generation (RAG) для повышения точности советов, выдаваемых большими языковыми моделями в контексте заболеваний кофейных листьев. Авторы показывают, как RAG помогает уменьшить риск «галлюцинаций» и улучшить достоверность предоставляемой информации
7	A. Tzachor, M. Devare, C. Richards, P. Pypers, A. Ghosh, J. Koo, et al. (2023) [12]	Исследователи анализируют перспективы внедрения LLM для консультационных служб в сельском хозяйстве, обеспечивая фермеров более точными и персонализированными рекомендациями. Акцент сделан на технологические и организационные аспекты масштабирования подобных сервисов
8	B. Zhao, W. Jin, J. Del Ser, G. Yang (2023) [14]	Работа направлена на улучшение многоязычной классификации аграрных текстов с помощью ChatGPT. Авторы демонстрируют, как внедрение таких моделей повышает эффективность анализа информации и облегчает коммуникацию между специалистами, говорящими на разных языках
9	J. Vadapalli, S. Gupta, B. Karki, C.-H. Tsai (2024) [13]	Авторы рассматривают, как интеграция пользовательских данных (например, от фермеров и ученых) может улучшить точность и релевантность LLM для агропромышленной сферы. Предлагается архитектура LLM, позволяющая динамически адаптировать модель под локальные условия и специфику конкретных хозяйств

Table 1

Overview of articles on the application of LLM in agriculture

No.	Authors, year	Brief description
1	A. Chebbi, G. Kniesel, N. Abdennadher, G. Dimarzo (2024) [1]	This study presents a method for entity recognition applied to textual data on agricultural goods using large language models. The proposed solution improves the accuracy of identifying key terms found in materials related to trade and logistics in the agro-industrial sector
2	C. Dhavale, T. Pawar, A. Singh, S. Pole, K. Sabat (2024) [2]	In this work, the authors combined GAN models to enhance image quality, CNN for plant disease detection, and an LLM as an intelligent assistant for farmers. This integrated approach facilitates diagnostics and enhances the competence of specialists in the agricultural field

3	<i>V. Madaan, G. Bindal, S. Singh, S. K. Yadav, A. Singh, P. Sinha, et al. (2023) [7]</i>	<i>The authors developed a hybrid system in which large language models interact with machine learning modules for accurate crop disease diagnosis. The paper provides practical use cases – from agronomist consultations to automated recommendations – thus streamlining decision-making processes for specific farms and agricultural enterprises under real field conditions</i>
4	<i>S. Stoyanov, M. Kumurdjieva, V. Tabakova-Komsalova, L. Doukovska (2023) [11]</i>	<i>This research describes the concept of “smart” cyber-physical systems in agriculture, managed by large language models. The implementation of such systems aims to improve coordination, resource management, and scalability of solutions for various agrotechnical tasks</i>
5	<i>J. Qing, X. Deng, Y. Lan, Z. Li (2023) [8]</i>	<i>This work demonstrates how a GPT model can complement computer vision capabilities in diagnosing plant diseases from images. The authors combine a lightweight YOLO algorithm with generative text descriptions to generate recommendations and conclusions for the agricultural sector</i>
6	<i>S. Selva Kumar, A. K. M. A. Khan, I. A. Banday, M. Gada, V. V. Shanbhag (2024) [9]</i>	<i>The article proposes a Retrieval-Augmented Generation (RAG) approach to enhance the accuracy of advice provided by large language models in the context of coffee leaf diseases. The authors show how RAG helps reduce the risk of “hallucinations” and improves the reliability of the information provided</i>
7	<i>A. Tzachor, M. Devare, C. Richards, P. Pypers, A. Ghosh, J. Koo, et al. (2023) [12]</i>	<i>The researchers analyze the prospects of implementing LLM for agricultural advisory services, providing farmers with more accurate and personalized recommendations. The focus is on the technological and organizational aspects of scaling such services</i>
8	<i>B. Zhao, W. Jin, J. Del Ser, G. Yang (2023) [14]</i>	<i>This paper aims to improve multilingual classification of agricultural texts using ChatGPT. The authors illustrate how integrating such models boosts efficiency in information analysis and facilitates communication among specialists speaking different languages</i>
9	<i>J. Vadapalli, S. Gupta, B. Karki, C.-H. Tsai (2024) [13]</i>	<i>The authors discuss how integrating user data (e. g., from farmers and researchers) can enhance the accuracy and relevance of LLM in the agro-industrial sphere. They propose an LLM architecture that dynamically adapts the model to local conditions and the specifics of particular farms</i>

Важной особенностью таких моделей является предварительная стадия обучения (pre-training), в ходе которой модель обрабатывает огромный разнообразный массив текстов (например, из интернета, книг, научных статей) без жесткой разметки, используя технологии больших данных. После этого, как правило, идет стадия дополнительной настройки (fine-tuning) на конкретных задачах или предметных областях. В результате модель может лучше ориентироваться в определенной тематике (например, сельском хозяйстве, медицине и др.). Наиболее известными примерами являются модели семейств GPT (Generative Pre-trained Transformer) и BERT (Bidirectional Encoder Representations from Transformers), а также их более новые итерации с расширенными возможностями, например Yandex GPT, GigaChat, Llama.

В последние годы сельское хозяйство совершило технологический сдвиг благодаря использованию всего арсенала современных инноваций: от дронов и спутникового мониторинга до больших данных (Big Data) и систем компьютерного зрения. Одна из основных тенденций в сельском хозяйстве состоит в интеграции AI-платформ деятельность агропромышленных экосистем. Традиционно специалисты различных профилей в сельском хозяйстве опирались либо на собственный опыт, либо на рекомендации агрономов, либо на методики, рекомендуемые учеными и регуляторами (мини-

стерствами и ведомствами) в сфере управления агропромышленным комплексом. Однако трансформация мировой экономики, связанная с глобализацией рынка сельскохозяйственной продукции и услуг, рост конкуренции, наконец, климатические изменения требуют для эффективного управления агропромышленным комплексом оперативного доступа к самому свежему и точному знанию, будь то научные исследования о новых сортах различных сельскохозяйственных культур, данные о специфике почв или прогнозы погоды. LLM могут аккумулировать эти массивы текстовой информации, анализировать их и выдавать релевантные рекомендации в зависимости от конкретной ситуации в стране, регионе или даже отдельной фермы или агрохолдинга.

Ниже представлена сводная таблица, в которой собраны наиболее значимые публикации о применении больших языковых моделей в сельском хозяйстве. В таблице кратко отражены основные идеи и выводы каждой работы.

Исходя из данных таблицы можно выделить по крайней мере два тренда в дальнейшем развитии LLM в сельском хозяйстве.

Первый тренд связан с развитием умных систем общения и поддержки, в том числе чат-ботов и виртуальных ассистентов, которые не только отвечают на короткие вопросы специалистов агрохолдинга, но и способны в интерактивном режиме вести

полноценный диалог о различных насущных проблемах сельхозпроизводителей: какие удобрения лучше использовать, как прогноз погоды повлияет на сроки посева или как предупредить нападение конкретных вредителей. Это становится возможным благодаря тому, что большие языковые модели, обученные на огромном массиве данных (агрономические справочники, научные статьи и др.), становятся практически экспертами-советчиками, доступными круглосуточно и не требующими личного присутствия конкретного специалиста.

Второй тренд – синергия LLM с технологиями компьютерного зрения (CV). С помощью дронов и различных IoT-устройств, включая камеры, собирается огромный объем визуальных данных: состояние листьев растений, цвет почвы, наличие сорняков или вредителей, которые CV-нейросети могут автоматически распознавать, выделяя конкретные объекты на изображениях, а LLM – интерпретировать полученные результаты. Таким образом, модель может «прочитать» результаты визуальной диагностики и сразу предложить соответствующие меры: «Обнаружен недостаток азота на данном участке поля, рекомендуется внести дополнительные удобрения», подкрепляя рекомендацию эмпирическими данными по региону.

Использование облачных платформ упрощает хранение данных, их анализ и развертывание готовых сервисов на базе LLM и других алгоритмов машинного обучения, а наличие открытых данных и стандартов взаимодействия датчиков и IoT-устройств формирует благоприятную среду, в которой большие языковые модели могут с легкостью «подтягивать» необходимую текстовую информацию или метаданные, объединяя разные источники в едином аналитическом контуре.

Таким образом, современные тенденции применения AI и сущность применения LLM в сельском хозяйстве можно охарактеризовать как переход к комплексным цифровым экосистемам, внутри которых модели машинного обучения взаимодействуют с IoT, Big Data и компьютерным зрением. Использование такого подхода дает возможность выстраивать точные прогнозы, автоматизировать коммуникации и формировать персонализированные рекомендации, кардинально меняя подход к управлению агропредприятиями и способствуя росту их конкурентоспособности на глобальном рынке.

Методология сбора и анализа данных

Для обеспечения воспроизводимости результатов предлагаемого нами исследования опишем методический подход, а по сути, методологию сбора и анализу данных. Как известно из практики анализа данных, методологический подход включает в себя два этапа: источники сбора данных и методы их анализа.

На экспериментальных сельскохозяйственных площадках необходимо проводить регулярные измерения с помощью IoT-сенсоров (температура и влажность почвы/воздуха, уровень освещенности, показатели содержания питательных веществ) и дронов с мультиспектральными камерами. Данные, собранные с помощью автоматизированных средств, необходимо верифицировать с помощью дополнительных и точечных замеров вручную. Такой подход будет исключать наличие выбросов в данных. Полученные таким образом данные необходимо загрузить в облачное хранилище, например на базе Яндекс Облака или иной платформы. В конечном счете можно получить цифровой двойник исследуемого участка.

Для проведения дальнейших экономических расчетов требуется изучить официальные статистические отчеты Министерства сельского хозяйства РФ и региональных департаментов АПК, а также данные из научной литературы и публикаций, посвященных экономической эффективности внедрения систем искусственного интеллекта в сельском хозяйстве. Кроме этого, для уточнения экономических расчетов требуется проанализировать рыночные данные об уровне цен на зерновые культуры, доступные в открытых источниках.

Для анализа данных, полученных с IoT-устройств, будут использованы методы статистического анализа данных, в частности, методы статистической фильтрации (z-score, IQR), которые позволят очистить данные от выбросов и пропущенных значений. В результате этого будет сформирована временная шкала изменений параметров для каждой зоны исследуемого участка, а это позволит оценить динамику агротехнических характеристик.

Для выявления признаков стресса растений (например, грибковых инфекций) необходимо использовать алгоритм сверточной нейронной сети (CNN), обученный в течение определенного времени на размеченных снимках пораженных и здоровых участков сельскохозяйственных угодий. Результаты классификации затем автоматически будут интегрированы с данными LLM-модели, которая предназначена для интерпретации полученной информации.

При оценке потенциальной выгоды от внедрения LLM необходимо учитывать динамику цен на сельскохозяйственную продукцию, возможные колебания спроса, а также косвенные выгоды (например, сокращение расходов на пестициды и фонд заработной платы при автоматизации части процессов).

В итоге экономическая эффективность модели оценивалась в формате анализа сценариев (консервативного, базового, оптимистичного), а итоговый показатель окупаемости рассчитывался методом дисконтированных денежных потоков (NPV).

Таким образом, в ходе исследования применялся комплексный подход, объединяющий сбор первичных полевых данных, их последующую валидацию и статистическую обработку, а также анализ финансово-экономических показателей с использованием общепринятых методов экономического анализа.

Практический пример использования и технической реализации LLM на примере конкретного кейса

Чтобы проиллюстрировать потенциал больших языковых моделей в реальной производственной среде, рассмотрим кейс. Пусть фермерское хозяйство в центральном регионе страны управляет полем в 500 га, на котором выращивается пшеница. Из-за особенностей климата и повышенной влажности пшеница неоднократно страдала от грибковых заболеваний, в первую очередь бурой ржавчины и мучнистой росы. Потери урожая в некоторые годы достигали 15–20 %. Ставится задача минимизации ущерба от болезней, повышения урожайности и качества зерна, сокращения избыточных расходов на фунгициды за счет точного расчета объема и своевременного применения.

Для решения задачи предлагаем построить умную ферму на следующей технической базе. Сначала устанавливаются 15–20 датчиков, контролирующих температуру почвы, влажность воздуха, содержание влаги в почве и уровень освещенности. Закупаются 1–2 дрона, оснащенные камерами в видимом и ближнем инфракрасном спектре. Дроны запускаются раз в неделю (либо по необходимости) для мониторинга состояния пшеницы. На снимках, получаемых с дронов, можно выявлять ранние признаки стресса растений (например, при начале распространения грибковое заболевание бурая ржавчина дает специфические световые «отпечатки» в ИК-диапазоне). Все собранные данные передаются через шлюзы в облако или на локальный сервер, где хранятся для последующего анализа.

С точки зрения ИТ-инфраструктуры создается единый аналитический pipeline, то есть данные от датчиков объединяются со снимками от дронов, далее алгоритмы компьютерного зрения выделяют проблемные участки поля. Результаты первичной обработки данных передаются в большую языковую модель, дообученную на специфическом корпусе текстов, включающих научные публикации о болезнях пшеницы, фитосанитарные отчеты, справочники по удобрениям и др. LLM анализирует информацию о погоде, показатели с датчиков, результаты «воздушной» съемки и сравнивает это с данными об известных грибковых заболеваниях пшеницы. На выходе формируются рекомендации: где и когда провести профилактику, какую комбинацию фунгицидов выбрать, чтобы не допустить развития болезни растений.

Для работников фермы разрабатывается мобильное приложение, в котором они видят карту поля (500 га) с цветовой индикацией проблемных зон. LLM генерирует текстовые рекомендации: «На участке № 3 уровень влажности и динамика температур благоприятствуют появлению бурой ржавчины. Рекомендуется опрыскивание фунгицидом X в дозировке Y в ближайшие 2–3 дня». При необходимости специалист, например агроном, может задать уточняющие вопросы системе, чтобы понять логику предложений (например, почему именно этот препарат эффективен) и получить ссылки на научные публикации и рекомендации соответствующих ведомств.

Возможно, кому-то покажется предложенный кейс несколько фантастичным, однако это не так, и мы приведем пример конкретной технической реализации и примерными расходами на ее осуществление.

Ниже приводится сводная таблица технической реализации и оценки затрат (таблица 2).

Ниже приводится примерная модель окупаемости для фермерского хозяйства (500 га), выращивающего зерновую культуру (например, пшеницу) (таблица 3).

Подведем итоги. Техническая часть (датчики, дроны, облачная инфраструктура и интеграция с LLM) требует стартовых инвестиций в среднем 2–5 млн руб., при этом более точный расчет зависит от выбранного уровня автоматизации. Операционные расходы (подписка, поддержка и обновление ИТ-инфраструктуры) составляют около 1 млн руб. в год.

При предположительном росте урожайности на 10 % и дополнительной экономии ресурсов сельхозпредприятие может увеличить годовой доход и сэкономить на пестицидах/логистике, суммарно получая около 3,4 млн руб. Таким образом, при грамотном внедрении системы на базе LLM сельхозпредприятие может достичь окупаемости инвестиций в среднем за 1,5–2 года, после чего внедренная система начнет приносить чистую прибыль и увеличивать рентабельность хозяйственной деятельности.

Таким образом, предложенный практический кейс демонстрирует, как большие языковые модели могут существенно повысить эффективность управления бизнес-процессами на сельскохозяйственном предприятии, позволяя не только реагировать на возникающие проблемы в режиме реального времени, но и предотвращать их появление на ранних этапах, тем самым повышая урожайность сельскохозяйственных культур.

Региональные особенности и риски внедрения LLM в условиях Российской Федерации

Разнообразие климатических, экономических и инфраструктурных условий России требует адаптации предложенного решения под специфику конкретных регионов.

Таблица 2

Карта технической реализации проекта

Экономика

Элемент	Описание	Ориентировочные затраты	Примечания
1. Датчики и IoT-оборудование	Набор датчиков для контроля температуры и влажности почвы/воздуха, уровня освещенности и определения спор грибов. Предполагается установка 15–20 датчиков на 500 га	300–500 тыс. руб.	Сумма зависит от бренда и качества сенсоров. При этом необходимо учесть, что ежегодная калибровка датчиков обычно обходится дешевле, чем покупка
2. Дроны с мультиспектральными камерами	Приобретаются 1–2 дрона для регулярного облета, оснащенные камерами видимого и ближнего инфракрасного спектра. Такое решение позволяет своевременно диагностировать стрессовые условия для растений	0,8–1,2 млн руб.	Стоимость включает сам дрон, камеру и ПО для планирования полетов. Необходимо учесть цену обслуживания: замена батарей, возможный ремонт и т. п.
3. Облачные сервисы и инфраструктура	Организация хранения данных и вычислительных ресурсов в облачных платформах (AWS, Google Cloud, Яндекс Облако). Подключение к API для работы с большой языковой моделью (YandexGPT-3 Pro или аналогичной)	50–100 тыс. руб/мес	Затраты варьируются в зависимости от количества обращений к модели и объемов хранимой информации
4. Доменное дообучение LLM	Дополнительная настройка (fine-tuning) большой языковой модели на корпусе текстов. Включает сбор и верификацию данных, а также тестирование и оптимизацию гиперпараметров	200 тыс. – несколько млн руб.	Одноразовые или периодические вложения. Точная сумма зависит от размера датасета и регулярности обновления модели. При большой выборке может потребоваться высокопроизводительный вычислительный кластер
5. Интеграция и разработка	Создание конвейера обработки данных (pipeline), проектирование пользовательского интерфейса (веб-приложение / мобильное приложение), интеграция с полевым оборудованием и облачными сервисами	1–3 млн руб.	Статья расходов зависит от нужного уровня кастомизации, числа внешних систем и квалификации команды разработчиков
6. Персонал и обучение	Подготовка работников сельхозпредприятия к работе с системой, обеспечение технической поддержки и организация обучающих мероприятий, связанных с использованием дронов, сенсоров и ПО	200–500 тыс. руб/год	Затраты могут быть частично включены в контракт с разработчиком. Включают консультации и при необходимости сертификацию операторов дронов

Table 2

Project Technical Implementation Map

Element	Description	Approximate costs	Notes
1. Sensors and IoT equipment	A set of sensors to monitor soil/air temperature and humidity, light levels, and detect fungal spores. It is assumed that 15–20 sensors will be installed over 500 hectares	300–500 thousand rubles	The total depends on the brand and quality of the sensors. Also note that annual sensor calibration is typically cheaper than purchasing new devices

2. Drones with multispectral cameras	One or two drones are purchased for regular flights, equipped with cameras in the visible and near-infrared spectrum. This solution allows for timely detection of plant stress factors	0.8–1.2 million rubles	The cost includes the drone itself, the camera, and software for flight planning. Maintenance expenses – such as battery replacement and potential repairs – should also be considered
3. Cloud services and infrastructure	Setting up data storage and computing resources on cloud platforms (AWS, Google Cloud, Yandex Cloud). Connecting to an API for working with a large language model (YandexGPT-3 Pro or equivalent)	50–100 thousand rubles/month	Costs vary depending on the number of model queries and the volume of stored data
4. Domain-specific LLM fine-tuning	Additional fine-tuning of a large language model on a text corpus. Includes data collection and verification, as well as testing and optimization of hyperparameters	200 thousand – several million rubles	These are one-time or periodic expenses. The exact amount depends on the dataset size and how frequently the model is updated. High-performance computing clusters may be required for large datasets
5. Integration and development	Creating a data processing pipeline, designing a user interface (web/mobile application), and integrating with field equipment and cloud services	1–3 million rubles	This cost item depends on the required level of customization, the number of external systems, and the developers' expertise
6. Personnel and training	Training agricultural enterprise staff to use the system, providing technical support, and organizing training activities related to operating drones, sensors, and software	200–500 thousand rubles/year	Some costs may be partially included in the developer contract. This item includes consultations and, if necessary, certification for drone operators

В рамках комплекса проблем, обсуждаемых в статье с учетом региональной специфики, можно выделить три региональных кластера: кластер 1 – южные регионы, кластер 2 – северные регионы и кластер 3 – уральский регион.

В зонах с более теплым и засушливым климатом (например, Краснодарском крае, Ростовской области) необходимо особенно уделять внимание системам орошения и искать пути оптимизации поливов на основе данных мониторинга влажности почвы. Использование LLM в рамках такой региональной специфики целесообразно для прогнозирования периодов засух, расчета необходимых объемов полива и выбора периодов агротехнических мероприятий.

В условиях Сибири особая роль в использовании LLM отводится предиктивным моделям, которые позволят минимизировать последствия поздних заморозков на этапе выращивания сельскохозяйственных культур.

В Уральском регионе – зоне рискованного земледелия LLM могут быть дообучены на исторических данных о погодных аномалиях, что позволит оптимально, с учетом региональной специфики определить периоды посевной и сбора урожая.

Определяя региональную специфику, стоит упомянуть и о различных инфраструктурных и экономических условиях.

Крупные агрохолдинги, обладая значительными финансовыми ресурсами, могут использовать для применения LLM комплексные (и достаточно дорогие) цифровые платформы с возможностью высокопроизводительных вычислений на основе глубокого анализа больших данных (Big Data).

Средние и малые фермерские хозяйства с весьма ограниченным бюджетом могут использовать в первую очередь базовый набор сенсоров, обеспечивающих точный прогноз погоды и специализированные LLM, обученные на данных, например, только по зерновым культурам. Для таких хозяйств для уменьшения рисков можно применять облачные схемы использования ИИ-сервисов, что позволит достаточно серьезно снизить размеры капитальных затрат на приобретаемое оборудование и поддержку ИТ-инфраструктуры.

Обратим внимание и на то, что в ряде регионов значительную часть фермеров составляет старшее поколение, а значит, в подавляющем большинстве случаев принятие решений идет с использованием традиционных сценариев. В таких условиях для интеграции инноваций и повышения доверия фермеров требуется использовать предварительную демонстрацию пилотных проектов и дружественный интерфейс сервисов, использующих LLM: например, чат-бот с голосовым управлением.

Таблица 3

Модель окупаемости проекта с учетом средней цены, установленной Минсельхозом в 2024–2025 в 12 000 руб. за 1 тонну пшеницы

Экономика

Параметр	Значение	Комментарии
1. Площадь поля	500 га	Рассматривается фермерское хозяйство среднего масштаба, ориентированное на зерновые культуры
2. Средняя урожайность до внедрения	4 т/га	Общий сбор до внедрения: 4 т/га × 500 га = 2000 т
3. Рыночная цена реализации	12 000 руб/т	Цена может меняться в зависимости от сорта пшеницы, уровня влажности зерна и прочих факторов рынка
4. Валовой доход до внедрения	24 млн руб.	2000 т × 12 000 руб/т = 24 млн руб.
5. Прирост урожайности за счет системы (прогноз)	+10 %	Связан со своевременной диагностикой болезней, оптимизированным поливом, внесением удобрений и другими мерами повышения эффективности
6. Новая урожайность	4,4 т/га	4 т/га + 10 % = 4,4 т/га; общий сбор: 4,4 т/га × 500 га = 2200 т
7. Валовой доход после внедрения	26,4 млн руб.	2200 т × 12 000 руб/т = 26,4 млн руб.
8. Дополнительный доход (рост выручки)	2,4 млн руб.	26,4 млн руб. – 24 млн руб. = 2,4 млн руб.
9. Экономия на ресурсах	~1 млн руб.	За счет более эффективного применения пестицидов и оптимизации логистики можно снизить расходы на сумму до 1 млн руб.
10. Итоговая годовая выгода	3,4 млн руб.	2,4 млн (увеличение выручки) + 1 млн (экономия) = 3,4 млн руб.
11. Стартовые затраты	2–5 млн руб.	Включают оборудование (датчики, дроны) и все расходы на интеграцию (см. таблицу 2)
12. Операционные расходы (ежегодно)	~1 млн руб.	Подписка на облачные сервисы, обслуживание датчиков, обучение персонала и обновления ПО
13. Период окупаемости	~1,5–2 года	Исходя из годовой выгоды (3,4 млн руб.) и потребности покрыть стартовые инвестиции и ежегодные расходы

Table 3

Project payback model considering the average price set by the Ministry of Agriculture for 2024–2025 at 12 000 rubles per ton of wheat

Parameter	Value	Comments
1. Field area	500 ha	A mid-sized farming enterprise focused on grain crops is considered
2. Average yield before system implementation	4 t/ha	Total harvest before implementation: 4 t/ha × 500 ha = 2,000 t
3. Market sale price	12,000 rub/t	The price may vary depending on the wheat variety, grain moisture level, and other market factors
4. Gross income before implementation	24 million rubles	2,000 t × 12,000 rub/t = 24 million rubles
5. Yield increase due to the system (forecast)	+10%	Associated with timely disease diagnostics, optimized irrigation, fertilizer application, and other measures to improve efficiency
6. New yield	4.4 t/ha	4 t/ha + 10 % = 4.4 t/ha; total harvest: 4.4 t/ha × 500 ha = 2,200 t
7. Gross income after implementation	26.4 million rubles	2,200 t × 12,000 rub/t = 26.4 million rubles
8. Additional income (revenue growth)	2.4 million rubles	26.4 million rubles – 24 million rubles = 2.4 million rubles
9. Resource savings	~1 million rubles	Through more efficient use of pesticides and optimized logistics, costs can be reduced by up to 1 million rubles
10. Total annual benefit	3.4 million rubles	2.4 million (increased revenue) + 1 million (savings) = 3.4 million rubles
11. Initial investment	2–5 million rubles	Includes equipment (sensors, drones) and all integration costs (see Table 2)
12. Operating expenses (annual)	~1 million rubles	Cloud service subscriptions, sensor maintenance, staff training, and software updates
13. Payback period	~1.5–2 years	Based on the annual benefit (3.4 million rubles) and the need to cover initial investments and yearly costs

Отметим, что, несмотря на очевидные преимущества, связанные с внедрением больших языковых моделей, существуют риски их неэффективного использования на практике. Всю систему рисков можно поделить на 3 больших блока: технологические, экономические и социальные.

К технологическим рискам следует отнести качество и объем данных, надежность инфраструктуры и информационная безопасность. Возникновение таких рисков могут приводить к неверным прогнозам, «галлюцинациям» модели и низкой точности рекомендаций. Кибератаки могут привести к утечкам данных и повлечь репутационные и финансовые потери для предприятий АПК.

Экономические риски связаны с колебанием цен на продукцию и ресурсы, а также первоначальными высокими стартовыми инвестициями в подобные проекты.

Социальные риски не менее опасны и могут быть представлены в виде следующей взаимосвязанной совокупности: сопротивление нововведениям и сокращением рабочих мест. Действительно, возникновение негативного восприятия цифровых технологий среди персонала предприятий АПК может повлиять на качество обучения LLM, а полная или частичная автоматизация некоторых традиционных бизнес-процессов в сельском хозяйстве может привести к высвобождению малоквалифицированных работников.

Меры минимизации такого рода рисков включают в себя поэтапный запуск (пилотные проекты с оценкой эффективности до масштабирования), привлечение экспертов в области информационной безопасности, своевременную адаптацию ИИ-моделей под региональные особенности, а также создание образовательных программ на базе отраслевых вузов, например Уральского государственного аграрного университета, для повышения цифровой грамотности специалистов в современном сельском хозяйстве Российской Федерации.

Успешное внедрение LLM в российский АПК напрямую зависит от способности сельскохозяйственных предприятий к гибкой адаптации в рамках учета многообразных региональных условий: климатических, экономических и инфраструктурных. Одновременно с этим крайне важно проводить со стороны научного сообщества и региональных властей комплексный анализ технологических, экономических и социальных рисков, позволяющий минимизировать возможные негативные последствия. Такой комплексный подход будет обеспечивать более высокую эффективность внедрения предлагаемых инноваций и способствовать устойчивому развитию сельхозпроизводства во всех регионах России.

Перспективы развития агропромышленного комплекса в России

Прогресс в области больших языковых моделей и искусственного интеллекта в целом идет очень

быстрыми темпами и влияет на перспективы развития в том числе и сельского хозяйства.

1. Персонализация систем управления. Технологии сбора данных становятся все более продвинутыми: сенсоры и датчики измеряют состояние почвы и растений на каждом квадратном метре, дроны облетают поля и делают подробные снимки, а спутниковые системы способны отслеживать динамику изменения ситуаций в течение всего времени – от посева до сборки урожая. Большие языковые модели следующего поколения смогут интегрировать данные с научными знаниями и практическим опытом, давая персонализированные рекомендации для каждого отдельно взятого случая. То есть LLM станут своеобразным «мозгом» – интеллектуальным помощником, который на основе всех потоков информации формирует оптимальную стратегию.

2. Комплексная интеграция с другими цифровыми технологиями. Широкое внедрение робототехники и автоматизированных систем управления сельхозтехникой позволит оптимизировать ее количество и снизить риски принятия ошибочных решений со стороны человека, поскольку такая сельхозтехника может получать команды «на лету» от специально настроенной LLM. Например, в России на ВДНХ в 2023 году была представлена компания Cognitive Pilot (Ольга Ускова), которая входит в 5 лучших мировых компаний (по версии США) по внедрению цифровых технологий и моделей искусственного интеллекта в АПК. В частности, этой компанией были разработаны работающие системы технического зрения для сельхозтехники, нейронная сеть Ипполит для общения с комбайнерами, ведутся работы по созданию и использованию ролевого интеллекта (когда совокупность машин сама принимает решения на основе обмена сообщениями между собой).

3. Специализированные LLM. Современные отечественные и зарубежные LLM обучаются на разноплановом и очень обширном корпусе текстов, что позволяет им быть универсальными. В будущем логичным шагом станет создание узкопрофильных (малых) LLM для АПК, обученных исключительно на данных, связанных с различными секторами сельского хозяйства. Такие агро-LLM смогут глубже понимать специфику деятельности различных специалистов в сельском хозяйстве и давать более точные ответы на вопросы, связанные с конкретными запросами специалистов в сфере АПК.

4. Международное сотрудничество и обмен данными. Вопрос продовольственной безопасности и повышения урожайности волнует все страны. Вполне реальным представляется то, что в недалеком будущем будут создаваться международные научно-исследовательские проекты и открытые базы данных и платформы, куда будут загружаться результаты экспериментов, и прочие релевантные

материалы (по аналогии с медициной). Большие языковые модели смогут централизованно обрабатывать этот массив знаний, генерируя рекомендации для определенных регионов с учетом международного опыта.

5. Автоматическая генерация обучающего контента и документов. Большие языковые модели уже сейчас могут автоматически генерировать учебные материалы, создавать инструкции и справочники. Поэтому LLM, опираясь на новые исследования в сфере сельского хозяйства, могут обновлять учебники, справочники и прочий контент для всех заинтересованных лиц, делая их доступными, например, в мобильном приложении или чат-боте. Реализация такой технологии даст возможность актуализировать знания в режиме реального времени, и не ждать, когда традиционная консервативная система образования переработает соответствующую программу обучения.

Таким образом, будущее применения больших языковых моделей в сельском хозяйстве лежит в глубокой интеграции с иными цифровыми технологиями, в повышении точности и персонализации рекомендаций, а также в улучшении механизмов интерпретации и совместного использования данных. Если все эти направления будут развиваться поступательно, мы можем ожидать значительного повышения эффективности и устойчивости сельскохозяйственного производства во всем мире.

Обсуждение и выводы (Discussion and Conclusion)

Развитие больших языковых моделей (LLM) открывает перед сельским хозяйством новые горизонты. Тенденции последних лет показывают, что AI-технологии позволяют решать широкий спектр задач – от прогнозирования урожайности и профилактики болезней до оптимизации цепочек поставок. При этом мы наблюдаем смещение парадигмы от «интуитивного» управления к «ориентированному на данные», где цифровые инструменты играют ключевую роль в анализе и синтезе разрозненной и неполной информации.

Одним из крупнейших преимуществ LLM является их способность обрабатывать и понимать огромное количество текстовых материалов. Сельское хозяйство традиционно опирается на обширные базы знаний: научные статьи, отчеты о погоде, инструкции по применению удобрений и пестицидов, нормативные акты, локальные практики

и т. д. Человек-эксперт, сколь бы опытным он ни был, физически не может оперативно учитывать и систематизировать все доступные источники, особенно если речь идет о больших массивах данных за многие годы. Большие языковые модели, напротив, способны не только «прочитать» этот корпус, но и на его основе генерировать релевантные рекомендации, уточнения и даже сформулировать новые гипотезы.

Однако важно помнить, что для эффективного внедрения LLM необходима развитая цифровая инфраструктура: датчики (IoT), каналы связи (5G, спутниковый интернет) и облачные вычислительные платформы. Без данных, поступающих с полей в режиме реального времени, а также без методов их верификации рекомендации модели могут оказаться не очень полезными или даже вредными. Именно поэтому успех проектов в сфере умного сельского хозяйства во многом зависит от коллаборации разработчиков AI, поставщиков агротехники и экспертов в сфере сельского хозяйства.

Практический кейс, приведенный в статье, демонстрирует, что эти технологии уже работают, а не являются лишь абстрактной концепцией. Достигнутые результаты – сокращение потерь, экономия ресурсов и более оперативное принятие решений – свидетельствуют о том, что в ближайшем будущем подобные системы станут стандартом для продвинутых предприятий АПК. Следующим шагом будет их масштабирование: выход на международные рынки, адаптация к различным региональным условиям и сотрудничество с научными учреждениями для постоянного обновления базы знаний.

В заключение можно сказать, что большие языковые модели способны сыграть ключевую роль в цифровой трансформации сельского хозяйства. Их умение интегрировать и интерпретировать разнородные данные дает основания полагать, что мы вступаем в новую эпоху сельскохозяйственного производства, где ручной труд и интуиция экспертов будут дополняться интеллектуальными технологиями. При правильной постановке целей и разумном регулировании такая эволюция сельского хозяйства пойдет на пользу не только специалистам, но и всему человечеству, обеспечивая более устойчивое, эффективное и экологичное производство продуктов питания.

Библиографический список

1. Chebbi A., Kniesel G., Abdennadher N., Dimarzo G. Enhancing named entity recognition for agricultural commodity monitoring with large language models // Proceedings of the 4th Workshop on Machine Learning and Systems. Geneva, Switzerland, 2024. DOI: 10.1145/3642970.3655846.
2. Dhavale C., Pawar T., Singh A., Pole S., Sabat K. Revolutionizing farming: GAN-enhanced imaging, CNN disease detection, and LLM farmer assistant // 2024 2nd International Conference on Computer, Communication and Control. Indore, India, 2024. DOI: 10.1109/IC457434.2024.10486501.

3. Elbasi E., Mostafa N., Zaki C., AlArnaout Z., Topcu A., Saker L. Optimizing agricultural data analysis techniques through AI-powered decision-making processes // *Applied Sciences*. 2024. DOI: 10.3390/app14178018.
4. Gandhi R., Chellam A., Prabhu T., Kathirvel C., Sivaramkrishnan M., Ramkumar S. Machine Learning Approaches for Smart Agriculture // 2022 6th International Conference on Computing Methodologies and Communication (ICCMC). 2022. Pp. 1054–1058. DOI: 10.1109/ICCMC53470.2022.9753841.
5. Klair Y. S., Agrawal K., Kumar A. Impact of generative ai in diagnosing diseases in agriculture // 2024 2nd International Conference on Disruptive Technologies (ICDT). Greater Noida, India, 2024. DOI: 10.3389/frfst.2024.1473357.
6. Krupitzer C. Generative artificial intelligence in the agri-food value chain – overview, potential, and research challenges // *Frontiers in Food Science and Technology*. 2024. DOI: 10.3389/frfst.2024.1473357.
7. Madaan V., Bindal G., Singh S., Yadav S. K., Singh A., Sinha P., et al. Integrating language models and machine learning for crop disease detection for farmer guidance [Электронный ресурс] // Workshop on Advances in Computational Intelligence (ACI-2023), co-located with ICAIDS-2023. Hyderabad, India, 2023. URL: <https://ceur-ws.org/Vol-3706/Paper11.pdf> (дата обращения: 01.02.2025).
8. Qing J., Deng X., Lan Y., Li Z. Gpt-aided diagnosis on agricultural image based on a new light YO-LOPC // *Computers and Electronics in Agriculture*. 2023. Vol. 213. Article number 108168. DOI: 10.1016/j.compag.2023.108168.
9. Selva Kumar S., Khan A. K. M. A., Banday I. A., Gada M., Shanbhag V. V. Overcoming LLM challenges using rag-driven precision in coffee leaf disease remediation [Электронный ресурс] // 2024 International Conference on Emerging Technologies in Computer Science for Interdisciplinary Applications (ICETCS). Bengaluru, India, 2024. URL: <https://arxiv.org/html/2405.01310v1> (дата обращения: 01.02.2025).
10. Shaikh F., Memon M., Mahoto N., Zeadally S., Nebhen J. Artificial Intelligence Best Practices in Smart Agriculture // *IEEE Micro*. 2022. Vol. 42. Pp. 17–24. DOI: 10.1109/MM.2021.3121279.
11. Stoyanov S., Kumurdjieva M., Tabakova-Komsalova V., Doukovska L. Using llms in cyber-physical systems for agriculture – ZEMELA // 2023 International Conference on Big Data, Knowledge and Control Systems Engineering (BdKCSE). Bengaluru, India, 2024. DOI: 10.1109/BdKCSE59280.2023.10339738.
12. Tzachor A., Devare M., Richards C., Pypers P., Ghosh A., Koo J., et al. Large language models and agricultural extension services // *Nature Food*. 2023. Vol. 4. Pp. 941–948. DOI: 10.1038/s43016-023-00867-x.
13. Vadapalli J., Gupta S., Karki B., Tsai C.-H. Incorporating citizen-generated data into large language models // *Proceedings of the 25th Annual International Conference on Digital Government Research*. New York, USA, 2024. DOI: 10.1145/3657054.3659119.
14. Zhao B., Jin W., Del Ser J., Yang G. Chatagri: exploring potentials of ChatGPT on cross-linguistic agricultural text classification // *Neurocomputing*. 2023. Vol. 557. Article number 126708. DOI: 10.1016/j.neucom.2023.126708.
15. Назаров Д. М. Модели LLM в экономике: новые подходы к анализу данных // *Экономический анализ: теория и практика*. 2025. Т. 24, № 1. С. 44–57. DOI: 10.24891/ea.24.1.44.
16. Файзуллин Р. В., Новикова О. А. Применение методов машинного обучения для прогнозирования в сельскохозяйственном секторе экономики // *Интеллектуальные системы в производстве*. 2024. Т. 22, № 2. С. 69–79. DOI: 10.22213/2410-9304-2024-2-69-79.

Об авторах:

Дмитрий Михайлович Назаров, доктор экономических наук, заведующий кафедрой бизнес-информатики, Уральский государственный экономический университет, Екатеринбург, Россия; ORCID 0000-0002-5847-9718, AuthorID 392155. *E-mail: slup2005@mail.ru*

Светлана Викторовна Бегичева, кандидат экономических наук, доцент кафедры бизнес-информатики, Уральский государственный экономический университет, Екатеринбург, Россия; ORCID 0000-0002-0551-1622, AuthorID 668409. *E-mail: begichevas@mail.ru*

Антон Андреевич Копнин, ассистент кафедры бизнес-информатики, Уральский государственный экономический университет, Екатеринбург, Россия; ORCID 0009-0007-2656-5842, AuthorID 1156983. *E-mail: antn4@yandex.ru*

References

1. Chebbi A., Kniesel G., Abdennadher N., Dimarzo G. Enhancing named entity recognition for agricultural commodity monitoring with large language models. *Proceedings of the 4th Workshop on Machine Learning and Systems*. 2024; Geneva, Switzerland, 22 April.

2. Dhavale C., Pawar T., Singh A., Pole S., Sabat K. Revolutionizing farming: GAN-enhanced imaging, CNN disease detection, and LLM farmer assistant. *2024 2nd International Conference on Computer, Communication and Control*. Indore, India, 2024. DOI: 10.1109/IC457434.2024.10486501.
3. Elbasi E., Mostafa N., Zaki C., AlArnaout Z., Topcu A., Saker L. Optimizing agricultural data analysis techniques through AI-powered decision-making processes. *Applied Sciences*. 2024. DOI: 10.3390/app14178018.
4. Gandhi R., Chellam A., Prabhu T., Kathirvel C., Sivaramkrishnan M., Ramkumar S. Machine Learning Approaches for Smart Agriculture. *2022 6th International Conference on Computing Methodologies and Communication (ICCMC)*. 2022; 1054–1058. DOI: 10.1109/ICCMC53470.2022.9753841.
5. Klair Y. S., Agrawal K., Kumar A. Impact of generative ai in diagnosing diseases in agriculture. *2024 2nd International Conference on Disruptive Technologies (ICDT)*. Greater Noida, India, 2024. DOI: 10.3389/frfst.2024.1473357.
6. Krupitzer C. Generative artificial intelligence in the agri-food value chain – overview, potential, and research challenges. *Frontiers in Food Science and Technology*. 2024. DOI: 10.3389/frfst.2024.1473357.
7. Madaan V., Bindal G., Singh S., Yadav S. K., Singh A., Sinha P., et al. Integrating language models and machine learning for crop disease detection for farmer guidance. *Workshop on Advances in Computational Intelligence (ACI-2023), co-located with the 2nd International Conference on Artificial Intelligence and Data Science (ICAIDS-2023)* [Internet]. Hyderabad, India, 2023 [cited 2025 Feb 01]. Available from: <https://ceur-ws.org/Vol-3706/Paper11.pdf>.
8. Qing J., Deng X., Lan Y., Li Z. Gpt-aided diagnosis on agricultural image based on a new light YOLOPC. *Computers and Electronics in Agriculture*. 2023; 213: 108168. DOI: 10.1016/j.compag.2023.108168.
9. Selva Kumar S., Khan A. K. M. A., Banday I. A., Gada M., Shanbhag V. V. Overcoming LLM challenges using rag-driven precision in coffee leaf disease remediation. *2024 International Conference on Emerging Technologies in Computer Science for Interdisciplinary Applications (ICETCS)* [Internet]. Bengaluru, India, 2024 [cited 2025 Feb 01]. Available from: <https://arxiv.org/html/2405.01310v1>.
10. Shaikh F., Memon M., Mahoto N., Zeadally S., Nebhen J. Artificial Intelligence Best Practices in Smart Agriculture. *IEEE Micro*. 2022; 42: 17–24. DOI: 10.1109/MM.2021.3121279.
11. Stoyanov S., Kumurdjieva M., Tabakova-Komsalova V., Doukovska L. Using llms in cyber-physical systems for agriculture – ZEMELA. *2023 International Conference on Big Data, Knowledge and Control Systems Engineering (BdKCSE)*. Bengaluru, India, 2024. DOI: 10.1109/BdKCSE59280.2023.10339738.
12. Tzachor A., Devare M., Richards C., Pypers P., Ghosh A., Koo J., et al. Large language models and agricultural extension services. *Nature Food*. 2023; 4: 941–948. DOI: 10.1038/s43016-023-00867-x.
13. Vadapalli J., Gupta S., Karki B., Tsai C.-H. Incorporating citizen-generated data into large language models. *Proceedings of the 25th Annual International Conference on Digital Government Research*. New York, USA, 2024. DOI: 10.1145/3657054.3659119.
14. Zhao B., Jin W., Del Ser J., Yang G. Chatagri: exploring potentials of ChatGPT on cross-linguistic agricultural text classification. *Neurocomputing*. 2023; 557: 126708. DOI: 10.1016/j.neucom.2023.126708.
15. Nazarov D. M. LLM models in economics: new approaches to data analysis. *Economic Analysis: Theory and Practice*. 2025; 24 (1): 44–57. DOI: 10.24891/ea.24.1.44. (In Russ.)
16. Faizullin R. V., Novikova O. A. Application of Machine Learning Methods for Forecasting in the Agricultural Sector of the Economy. *Intellekt. Sist. Proizv.* 2024; 22 (2): 69–79. DOI: 10.22213/2410-9304-2024-2-69-79. (In Russ.)

Authors' information:

Dmitriy M. Nazarov, doctor of economic sciences, head of the department of business informatics, Ural State University of Economics, Ekaterinburg, Russia; ORCID 0000-0002-5847-9718, AuthorID 39215.

E-mail: slup2005@mail.ru

Svetlana V. Begicheva, candidate of economic sciences, associate professor of the department of business informatics, Ural State University of Economics, Ekaterinburg, Russia; ORCID 0000-0002-0551-1622, AuthorID 668409. *E-mail: begichevas@mail.ru*

Anton A. Kopnin, assistant of the department of business informatics, Ural State University of Economics, Ekaterinburg, Russia; ORCID 0009-0007-2656-5842, AuthorID 1156983. *E-mail: anttn4@yandex.ru*