

УДК004.42:633.7

Краткое сообщение



Открытый доступ

DOI: 10.32634/0869-8155-2025-395-06-162-166

А.И. Капитанов

Национальный исследовательский университет «МИЭТ», Москва, Россия

✉ andrey@kapdx.ru

Поступила в редакцию: 06.04.2025

Одобрена после рецензирования: 16.05.2025

Принята к публикации: 30.05.2025

© Капитанов А.И.

Эффективные методы адаптации LLM к доменной специфике аграрного бизнеса

РЕЗЮМЕ

В статье рассматриваются актуальные проблемы применения больших языковых моделей (LLM) в сфере аграрного бизнеса и предлагаются современные подходы к их решению. Несмотря на высокую эффективность LLM в обработке естественного языка, их адаптация к задачам аграрной отрасли связана с рядом сложностей. Ключевые проблемы включают формирование специализированных обучающих корпусов, баланс между качеством ответов и вычислительными затратами, объективную оценку качества моделей и их интеграцию в существующие аграрные информационные системы. Рассматриваются практические подходы к решению этих проблем, включая дообучение моделей на специализированных данных, методы оптимизации вычислений и применение гибридных архитектур (в частности, RAG). Анализируются основные направления применения LLM: генерация текстовых данных, улучшение поисковых систем, анализ пользовательских отзывов и автоматизация клиентской поддержки. Исследование направлено на повышение точности, релевантности и персонализации ответов моделей в задачах прогноза, анализа и автоматизации процессов в сельском хозяйстве. Предложенные решения способствуют эффективному внедрению LLM в инфраструктуру аграрного сектора, улучшая качество принятия решений, прогнозирование и автоматизацию бизнес-процессов

Ключевые слова: LLM, fine-tuning, RAG, семантический поиск, адаптация модели, персонализация, генеративные модели

Для цитирования: Капитанов А.И. Эффективные методы адаптации LLM к доменной специфике аграрного бизнеса. *Аграрная наука*. 2025; 395(06): 162–166.

<https://doi.org/10.32634/0869-8155-2025-395-06-162-166>

Short communications



Open access

DOI: 10.32634/0869-8155-2025-395-06-162-166

Andrey I. Kapitanov

National Research University "MIET", Moscow, Russia

✉ andrey@kapdx.ru

Received by the editorial office: 06.04.2025

Accepted in revised: 16.05.2025

Accepted for publication: 30.05.2025

© Kapitanov A.I.

Effective Methods for Adapting LLM to the Agricultural Business Domain

ABSTRACT

The article discusses the current challenges of applying large language models (LLMs) in the agricultural business sector and proposes modern approaches to address these issues. Despite the high effectiveness of LLMs in natural language processing, their adaptation to the tasks of the agricultural industry involves a number of difficulties. Key problems include the formation of specialized training corpora, balancing the quality of responses with computational costs, objective evaluation of model quality, and their integration into existing agricultural information systems. Practical approaches to solving these problems are discussed, including fine-tuning models on specialized data, computational optimization methods, and the use of hybrid architectures (in particular, RAG). The main areas of LLM application are also analyzed: text generation, search engine improvement, analysis of user reviews, and customer support automation. The research aims to improve the accuracy, relevance, and personalization of model responses in tasks related to forecasting, analysis, and automation of processes in agriculture. The proposed solutions contribute to the effective integration of LLMs into the infrastructure of the agricultural sector, enhancing decision-making quality, forecasting, and business process automation

Key words: LLM, fine-tuning, RAG, semantic search, model adaptation, personalization, generative models

For citation: Kapitanov A.I. Effective Methods for Adapting LLM to the Agricultural Business Domain. *Agrarian science*. 2025; 395(06): 162–166 (in Russian).

<https://doi.org/10.32634/0869-8155-2025-395-06-162-166>

Введение/Introduction

Современные LLM демонстрируют высокую эффективность в обработке естественного языка, однако их применение в аграрном бизнесе связано со следующими ключевыми проблемами. LLM создают новые возможности в области обработки естественного языка и искусственного интеллекта благодаря их способности решать новые задачи без дополнительного обучения [1]. Однако особенности данных, в частности данные о сельскохозяйственных товарах, отзывы фермеров, климатические условия и отчеты о состоянии почвы, требуют особой обработки, поскольку эти данные обладают нетривиальной структурой и терминологией. Кроме того, важную роль играет актуальность данных в аграрном бизнесе: информация о погодных условиях, урожайности, ценах на сельхозпродукцию и изменениях в законодательстве постоянно обновляется. Однако большинство LLM не имеют доступа к таким динамичным данным, что ограничивает их применение для генерации актуальных и точных ответов в аграрной сфере.

Методы адаптации LLM, такие как fine-tuning и LoRA, требуют значительных вычислительных ресурсов [2] и не всегда подходят для оперативного внедрения, в то время как стандартные подходы, применяющие вероятностную функцию ранжирования BM25 или dense retrieval, имеют свои ограничения: BM25 плохо работает с синонимами и переформулированными предложениями, а dense retrieval не всегда «воспринимает» тонкие семантические различия. Техники prompt engineering эффективны, однако требуют затрат на ручной подбор формулировок, что снижает масштабируемость. Кроме того, проблемы, связанные с качеством обучающих данных и трудностью оценки моделей с точки зрения реальных потребностей бизнеса, делают процесс адаптации еще более сложным.

LLM предоставляют широкие возможности для автоматизации и персонализации взаимодействия с фермерами и агробизнесом. Они активно применяются для автоматической генерации контента: описаний сельскохозяйственных товаров, маркетинговых материалов (в частности, рекламных текстов и емейл-рассылок для фермеров), а также локализации контента с учетом региональных и климатических различий. Это значительно упрощает работу с аграрным контентом и повышает его релевантность для различных целевых групп и рынков.

Применение больших языковых моделей повышает качество поиска и рекомендаций, внедряя семантический поиск, который анализирует смысл запросов, связанных с сельским хозяйством, а не только ключевые слова. Модели предоставляют персонализированные рекомендации на основе поведения пользователей и их историй покупок. Кроме того, LLM помогают улучшить структуру каталогов товаров, автоматизируя их

категоризацию, что облегчает навигацию и индексацию для фермеров и агробизнеса. Чат-боты и голосовые ассистенты обеспечивают быстрые ответы на запросы пользователей, помогают с выбором товаров, отслеживанием поставок и решением вопросов по возвратам.

В сфере анализа отзывов и поведения пользователей LLM помогают анализировать обратную связь, классифицируя отзывы по тональности и выявляя ключевые темы [3–5], что позволяет оперативно реагировать на проблемы и улучшать продукцию. Модели способны выявлять тренды и прогнозировать предпочтения клиентов на основе данных социальных сетей и отзывов, что помогает адаптировать ассортимент и маркетинговые стратегии.

Таким образом, применение LLM в аграрном бизнесе позволяет сделать платформы более персонализированными и эффективными, улучшая качество обслуживания и повышая конверсию.

Цель исследования — оценить возможности применения больших языковых моделей (LLM) для автоматизации контент-генерации, персонализации сервисов и аналитики в агробизнесе с целью повышения эффективности цифровых платформ АПК.

Материалы и методы исследования / Materials and methods

Для адаптации моделей применяют различные методы fine-tuning. Полное дообучение всех параметров в формализованном виде представляется как задача минимизации функции потерь:

$$\theta^* = \arg \min_{\theta} \sum^N L(f_{\theta}(x_i), y_i),$$

где θ — параметры модели, x_i — входные данные, y_i — ожидаемые выходные данные, L — функция потерь.

Для сокращения вычислительных затрат применяют методы параметрической адаптации, такие как LoRA и PEFT, позволяющие изменять только небольшие адаптационные матрицы. Такой подход снижает требования к памяти и ускоряет обучение. Метод instruction tuning улучшает контекстное представление ответов за счет обучения модели на размеченных примерах с инструкциями.

Для повышения актуальности ответов LLM применяют метод RAG, который сочетает генеративные возможности модели с доступом к внешним источникам информации [6]. В контексте аграрного бизнеса это особенно полезно при обработке клиентских запросов, требующих оперативного доступа к характеристикам товаров, данным о наличии и ценах. Интеграция LLM с базами знаний и товарными каталогами позволяет обеспечивать актуальные и персонализированные рекомендации, учитывая динамические изменения в ассортименте, ценах и наличии товаров. В этом

процессе важную роль играют векторные базы данных, которые используют метод ближайших соседей (kNN) для быстрого поиска релевантной информации.

Помимо методов дообучения, улучшение качества генерации возможно без изменения параметров модели. Оптимизация промптов, включая подходы zero-shot и few-shot, позволяет корректировать поведение модели на этапе запроса [7].

Дополнительные методы, такие как Chain-of-Thought, помогают модели «рассуждать» пошагово, а ReAct объединяет генерацию и взаимодействие с внешними инструментами для динамического поиска информации. Метод Self-Consistency в свою очередь позволяет оценивать несколько вариантов ответа и выбирать наиболее вероятный [8].

Эффективная адаптация LLM достигается при комбинировании нескольких подходов. Гибридные модели, совмещающие fine-tuned LLM и RAG, обеспечивают высокую точность ответов и актуальность данных без необходимости частого переобучения. Комплексный подход к адаптации LLM делает ее мощным инструментом для повышения качества клиентского сервиса и оптимизации бизнес-процессов. Применение комбинации fine-tuning, RAG, векторных баз данных и методов промпт-инжиниринга позволяет моделям не только эффективно понимать запросы пользователей, но и предоставлять точные, персонализированные и актуальные ответы.

Результаты и обсуждение / Results and discussion

Оценка качества адаптации LLM к аграрному бизнесу требует комплексного подхода, сочетающего традиционные NLP-метрики и бизнес-ориентированные показатели. При анализе генеративных моделей учитываются точность совпадений с эталонными ответами, полнота и связность текстов, а также способность модели учитывать синонимы и морфологию. Особое внимание уделяется релевантности первых позиций в выдаче, что критично для систем поиска и рекомендаций.

Количественные метрики не всегда отражают восприятие пользователями. Высокие значения полученных метрик не гарантируют, что модель создает убедительные и информативные описания товаров. Поэтому автоматический анализ дополняется ручной проверкой, включающей экспертную оценку соответствия ответа контексту, естественности текста и его полезности для потребителей. Важными аспектами становятся точность передачи характеристик товаров, корректность рекомендаций и отсутствие дезинформирующих генераций.

Ручная экспертная оценка дополняет автоматические метрики, позволяя учесть субъективные факторы, такие как удобочитаемость текста и его соответствие пользовательским ожиданиям. Конечные пользователи оценивают, насколько ответ

соответствует запросу, легко ли он воспринимается и насколько он способствует принятию решений. Такой подход особенно важен при создании описаний товаров и персонализированных предложений.

Окончательная проверка качества адаптации модели проводится через A/B-тестирование. Этот метод помогает определить влияние модели на ключевые бизнес-метрики: конверсию, средний чек и коэффициент отказов. Анализируются поведенческие паттерны, включая изменение времени на странице, глубину просмотра каталога и реакцию пользователей на представленные рекомендации. Дополнительно внедряются механизмы обратной связи, позволяющие пользователям оценивать релевантность ответов.

Совмещение автоматических метрик, экспертных оценок и анализа поведения пользователей позволяет наиболее точно определить, насколько успешно модель адаптирована к специфике аграрной отрасли. Такой подход обеспечивает не только количественное, но и качественное понимание ее эффективности в реальных условиях.

Для объективной оценки качества текстов, полученных после адаптации модели, проведен автоматический анализ с применением метрик *BLEU*, *ROUGE*, *METEOR* и *BERTScore*. Данные показатели позволяют оценить степень совпадения сгенерированных описаний товаров с эталонными текстами, выявляя различия на уровне точности, полноты, морфологической близости и семантической эквивалентности.

Анализ проводили на выборке описаний сельскохозяйственных товаров, включающей оригинальные тексты, а также их сгенерированные версии до и после применения гибридного подхода к адаптации модели. На первом этапе оценивали качество текстов, созданных базовой моделью, после чего проводили дообучение на специализированных данных о товарах. Повторная генерация проходила аналогичную проверку. В качестве базовой модели (baseline) применяли Mixtral 8x7B (лицензия Apache 2.0, США). Оригинальные данные получены из открытых источников и включали в себя наименования и описания товаров, которые рассматривали в качестве эталонных. Всего собрано 100 тыс. товарных позиций, представляющих широкий спектр категорий, что позволило обеспечить разнообразие входных данных и повысить обобщаемость модели.

Метрика *BLEU* измеряет точность совпадений n -грамм между сгенерированным текстом и эталонным описанием. Она рассчитывается следующим образом:

$$BLEU = BP \times \exp\left(\sum_{n=1}^N w_n \log p_n\right),$$

где: p_n — доля n -грамм в сгенерированном тексте, найденных в эталонном описании; w_n — вес соответствующей n -граммы; BP — штраф за слишком короткие тексты.

Метрика *ROUGE* оценивает полноту генерации, анализируя покрытие фраз из эталонного текста. Для *ROUGE-N* значение рассчитывается по формуле [9]:

$$ROUGEN = \frac{\sum_{s \in \{RefSum\}} \sum_{gram_n \in S} Count_{match}(gram_n)}{\sum_{s \in \{RefSum\}} \sum_{gram_n \in S} Count(gram_n)},$$

где n — размер n -граммы.

По аналогии с обычными метриками *BERTScore* вычисляет оценку сходства для каждой лексемы в сгенерированном предложении с каждой лексемой в эталонном предложении [10]. *METEOR* учитывает морфологические преобразования, такие как синонимы и разные формы слов. Она рассчитывается на основе F -меры, но с учетом точности и полноты:

$$METEOR = F_{mean} \times (1 - penalty),$$

где F_{mean} — гармоническое среднее точности и полноты, $penalty$ — штраф за неправильный порядок слов и разрывы в совпадениях.

Результаты эксперимента показали, что адаптация модели привела к улучшению качества сгенерированных товарных описаний. Увеличение показателя, отражающего способность модели учитывать синонимы, свидетельствует о более точном восприятии языковых вариаций, а повышение другого показателя указывает на улучшение семантической близости между эталонными и сгенерированными текстами.

Однако автоматические методы оценки имеют свои ограничения: они ориентированы на точные совпадения, что не всегда отражает естественность текста, а также зависят от характеристик предобученных моделей. Поэтому в дальнейшем анализ должен включать экспертную разметку и A/B-тестирование, что позволит более полно оценить эффективность адаптированной модели в реальных условиях аграрного бизнеса.

Таблица. Результаты экспериментальной оценки качества модели

Table. Results of the experimental evaluation of the model quality

Метрика	Baseline	Адаптированная модель
BLEU	0,1592	0,1628
ROUGE	0,4632	0,5461
BERTScore	0,8285	0,8523
METEOR	0,4658	0,5325

Выводы/Conclusions

В результате анализа существующих методов выявлено, что гибридные методы, включающие в себя fine-tuning, RAG, векторные базы данных и техники prompt engineering, наиболее эффективны при адаптации LLM для применения в аграрном бизнесе. Данные методы не только улучшают понимание специфической терминологии, но и повышают точность и актуальность выдачи информации. Fine-tuning, включая LoRA и PEFT, позволяют снижать вычислительные затраты, а применение RAG дает возможность оперативного доступа к динамическим данным. Техники prompt engineering, такие как Chain-of-Thought и Self-Consistency, улучшат генерацию текстов без необходимости изменять вес модели.

Важно дополнить объективные метрики экспертной оценкой и анализом пользовательского опыта для более точного соответствия бизнес-задачам. A/B-тестирование и обратная связь помогают измерить влияние на ключевые показатели, такие как конверсия и удовлетворенность клиентов.

Таким образом, комплексный подход к адаптации LLM повышает их ценность для автоматизации и персонализации взаимодействия в аграрном бизнесе, а дальнейшие исследования нацелены на совершенствование методов адаптации и расширение возможностей этих моделей в сельском хозяйстве.

Автор несет ответственность за работу и представленные данные. Автор несет ответственность за плагиат. Автор объявил об отсутствии конфликта интересов.

The author is responsible for the work and the submitted data. The author is responsible for plagiarism. The author declared no conflict of interest.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК / REFERENCES

- Pan S., Luo L., Wang Y., Chen C., Wang J., Wu X. Unifying Large Language Models and Knowledge Graphs: A Roadmap. *IEEE Transactions on Knowledge and Data Engineering*. 2024; 36(7): 3580–3599. <https://doi.org/10.1109/TKDE.2024.3352100>
- Hu E.J. et al. LoRA: Low-Rank Adaptation of Large Language Models. *arXiv*. 2106.09685. <https://doi.org/10.48550/arXiv.2106.09685>
- Feldman P., Dant A., Foulds J.R., Pan S. Polling Latent Opinions: A Method for Computational Sociolinguistics Using Transformer Language Models. *arXiv*. 2204.07483. <https://doi.org/10.48550/arXiv.2204.07483>
- Rusnachenko N., Golubev A., Loukachevitch N. Large Language Models in Targeted Sentiment Analysis for Russian. *Lobachevskii Journal of Mathematics*. 2024; 45(7): 3148–3158. <https://doi.org/10.1134/S1995080224603758>
- Krishnan A. Exploring the Power of Topic Modeling Techniques in Analyzing Customer Reviews: A Comparative Analysis. *arXiv*. 2308.11520. <https://doi.org/10.48550/arXiv.2308.11520>

6. Lewis P. *et al.* Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks. *arXiv*. 2005.11401. <https://doi.org/10.48550/arXiv.2005.11401>
7. Chamieh I., Zesch T., Giebertmann K. LLMs in Short Answer Scoring: Limitations and Promise of Zero-Shot and Few-Shot Approaches. *Proceedings of the 19th Workshop on Innovative Use of NLP for Building Educational Applications (BEA 2024)*. Association for Computational Linguistics. 2024; 309–315.
8. Chen X. *et al.* Universal Self-Consistency for Large Language Model Generation. *arXiv*. 2311.17311. <https://doi.org/10.48550/arXiv.2311.17311>
9. Lin C.-Y. ROUGE: A Package for Automatic Evaluation of Summaries. *Text Summarization Branches Out*. Association for Computational Linguistics. 2004; 74–81.
10. Zhang T., Kishore V., Wu F., Weinberger K.Q., Artzi Y. BERTScore: Evaluating Text Generation with BERT. *arXiv*. 1904.09675. <https://doi.org/10.48550/arXiv.1904.09675>
11. Banerjee S., Lavie A. METEOR: An Automatic Metric for MT Evaluation with Improved Correlation with Human Judgments. *Proceedings of the ACL Workshop on Intrinsic and Extrinsic Evaluation Measures for Machine Translation and (or) Summarization*. Association for Computational Linguistics. 2005; 65–72.

ОБ АВТОРАХ**Андрей Иванович Капитанов**

кандидат технических наук, доцент
andrey@kapdx.ru

Национальный исследовательский университет «МИЭТ»,
пл. Шокина, 1, Москва, 124498, Россия

ABOUT THE AUTHORS**Andrey Ivanovich Kapitanov**

Candidate of Technical Sciences, Associate Professor
andrey@kapdx.ru

National Research University "MIET",
1 Shokina Square, Moscow, 124498, Russia

**АГРАРНАЯ
НАУКА****AGRARIAN
SCIENCE**

Ежемесячный научно-теоретический и производственный журнал выходит один раз в месяц.



Научно-теоретический и производственный журнал «Аграрная наука» включен в Перечень ведущих рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученых степеней доктора и кандидата наук (К1, К2), в список Russian Science Citation Index (RSCI), в систему Российского индекса научного цитирования (РИНЦ), в ядро РИНЦ, «Белый список» ВАК РФ, в список периодических изданий Международной базы данных AGRIS (ГНУ ЦНСХБ Россельхозакадемии).

Ознакомиться с информацией о перечне специальностей ВАК и итоговом распределении журналов по категориям можно здесь:



Приравнивание научных журналов, входящих в наукометрические базы данных, к журналам Перечня ВАК с распределением по категориям:



Согласно приведенным данным, журнал «Аграрная наука» относится к категории К1.

Реклама

Подобную информацию о журнале можно получить у научного редактора М.Н. Долгой
+7 (495) 777 67 67 (доб. 1453)
dolgaya@vicgroup.ru