

УДК 004.89

АДАПТАЦИЯ БОЛЬШОЙ ЯЗЫКОВОЙ МОДЕЛИ ДЛЯ ГЕНЕРАЦИИ ПЕРСОНАЛИЗИРОВАННЫХ ОТЧЕТОВ ОБ УЧЕБНОЙ АКТИВНОСТИ

Светлов Борис Дмитриевич,

Соискатель, Национальный исследовательский ядерный университет «МИФИ», Москва,
Российская Федерация, Институт интеллектуальных кибернетических систем, кафедра
«Компьютерные системы и технологии»
e-mail: alb1rio@mail.ru

Красникова Светлана Анатольевна,

Старший преподаватель кафедры «Компьютерные системы и технологии», Национальный
исследовательский ядерный университет «МИФИ», Москва, Российская Федерация,
Институт интеллектуальных кибернетических систем,
sakrasnikova@mephi.ru

Аннотация

В статье рассматривается задача адаптации локальной большой языковой модели для автоматического формирования персонализированных отчетов об учебной активности учащихся по событийным данным интерактивной образовательной платформы, представляющим собой отобранный набор значимых параметров из логов взаимодействия учащегося с платформой. Исходные события платформы предварительно очищаются и агрегируются в набор аналитических показателей, включающий точность выполнения заданий, завершенность, регулярность занятий, время работы, предметный разрез и индекс вовлеченности. Базовая модель LLaMA на 8 млрд параметров не обеспечивала устойчивого соблюдения редакционного формата и допускала появление неподтвержденных утверждений и выводов. Для предметной адаптации применено параметрически эффективное дообучение LoRA поверх 4-битной квантованной модели (QLoRA). Качество текстов оценивалось по метрикам Coverage, Faithfulness, Distinct-N, Format compliance и ROUGE, а также с помощью экспертной оценки. В контрольном эксперименте после адаптации Coverage и Faithfulness достигли 1,00, Format compliance увеличилась с 0,67 до 1,00, ROUGE-1 F1 — с 0,40 до 0,59, ROUGE-2 F1 — с 0,13 до 0,22. Значения метрик, полученные после дообучения, показывают применимость параметрически эффективного дообучения для формирования структурированных и фактически согласованных образовательных отчетов при локальном развертывании модели.

Ключевые слова: дополнительное образование, кластерная интеграция, микроквалификации, предиктивная аналитика, профессиональная ориентация, сетевое взаимодействие, среднее профессиональное образование, управление образованием.

ADAPTATION OF A LARGE LANGUAGE MODEL FOR GENERATING PERSONALIZED REPORTS ON STUDENT LEARNING ACTIVITY

Svetlov Boris Dmitrievich,

Degree Candidate, National Research Nuclear University MEPhI, Moscow, Russian Federation
Institute of Cyber Intelligent Systems, Department of Computer Systems and Technologies
e-mail: alb1rio@mail.ru

Krasnikova Svetlana Anatolevna,

Senior Lecturer, Department of Computer Systems and Technologies, National Research Nuclear University MEPhI. Moscow, Russian Federation
Institute of Cyber Intelligent Systems,
sakrasnikova@mephi.ru

ABSTRACT

The paper addresses the adaptation of a locally deployed large language model for the automatic generation of personalized reports on students' learning activity based on event data from an interactive educational platform. These data represent a selected set of meaningful parameters extracted from logs of students' interactions with the platform. Raw platform events are first cleaned and aggregated into a set of analytical indicators, including task accuracy, completion rate, study regularity, learning time, subject-level performance, and an engagement index. The baseline 8-billion-parameter LLaMA model did not consistently comply with the required editorial format and could produce unsupported statements and conclusions. For domain adaptation, parameter-efficient Low-Rank Adaptation (LoRA) was applied on top of a 4-bit quantized model using the QLoRA approach. Text quality was evaluated using Coverage, Faithfulness, Distinct-N, Format compliance, and ROUGE metrics, as well as through expert assessment. In the control experiment, after adaptation, Coverage and Faithfulness reached 1.00, Format compliance increased from 0.67 to 1.00, ROUGE-1 F1 from 0.40 to 0.59, and ROUGE-2 F1 from 0.13 to 0.22. The metric values obtained after fine-tuning indicate the applicability of parameter-efficient fine-tuning for generating structured and factually consistent educational reports in a local model deployment setting.

Keywords: large language models, LLaMA, LoRA, QLoRA, learning analytics, personalized reports, text generation, EdTech.

Введение

Цифровые образовательные платформы формируют детальный цифровой след учащегося: фиксируются факты запуска и завершения заданий, число попыток, время работы, результат проверки, предмет, тип и сложность упражнения. В отличие от традиционной итоговой отметки, такие события позволяют анализировать не только результат обучения, но и сам процесс: регулярность занятий, устойчивость учебного ритма, динамику точности, распределение активности по предметам и признаки затруднений. Развитие аналитики образовательных платформ связано именно с использованием подобных данных для поддержки решений участников образовательного процесса [1, 2].

При этом сырые логи мало пригодны для непосредственного представления родителям. Технические идентификаторы, временные метки и отдельные числовые поля необходимо предварительно очистить, нормализовать и агрегировать. Даже после этого набор показателей остается сложным для интерпретации без пояснения контекста. Поэтому

практической задачей становится автоматическое преобразование логов образовательной платформы в краткий и понятный персонализированный отчет, содержащий общий вывод, сильные стороны, зоны роста и рекомендации.

Большие языковые модели позволяют решать такую задачу без жесткого набора заранее заданных текстовых шаблонов. Современные модели семейства LLaMA способны формировать связный текст на естественном языке и адаптироваться к инструкциям [3]. При этом для корректной работы с данными конкретного образовательного продукта, необходимо учитывать возможные отклонения от редакционной политики, требуемой структуры, объема, стилистическую нестабильность и галлюцинации (утверждения, не подтвержденные данными логов). Для отчетов о результатах образовательной деятельности, такая ошибка снижает практическую ценность результата.

Полное дообучение крупной модели требует значительных вычислительных ресурсов. Альтернативой выступают методы параметрически эффективной адаптации. LoRA замораживает базовые веса трансформера и обучает небольшие низкоранговые матрицы в целевых слоях [4]. Подход QLoRA дополнительно использует квантование базовой модели до 4 бит, сохраняя обучение LoRA-адаптеров и существенно снижая требования к видеопамяти [5]. Это делает метод подходящим для локального развертывания прикладных LLM-систем.

В настоящей работе рассматривается адаптация LLaMA-модели к узкой задаче формирования родительских отчетов по данным образовательной платформы. Исследование является развитием автоматизированной системы аналитической обработки учебных логов, в которой языковая модель получает не сырой набор данных, а предварительно рассчитанный и проверенный набор показателей. Такой способ позволяет разделить детерминированную аналитическую часть и вероятностную генерацию текста: числовые значения рассчитываются программно, а LLM отвечает за их интерпретацию.

Цель исследования

Цель исследования заключается в разработке и тестировании способа дообучения локальной большой языковой модели для генерации персонализированных отчетов об учебной активности учащихся, которые соответствовали бы заданной структуре и сохраняли фактическую согласованность с исходными показателями. Для достижения цели необходимо было определить формат входных данных и отчета, выбрать метод дообучения, сформировать набор метрик оценки отчета и сравнить результаты базовой и дообученной моделей на контрольном примере.

Материалы и методы исследования

Исследование проводилось в 2026 году на базе Института интеллектуальных кибернетических систем НИЯУ МИФИ в рамках разработки прототипа автоматизированной системы аналитической обработки данных об учебной активности учащихся. Экспериментальная проверка выполнялась на обезличенных данных коммерческой образовательной платформы российской EdTech-компании, ориентированной на детей дошкольного и младшего школьного возраста и предназначенной для подготовки к школе и углубленного освоения школьной программы в игровом формате.

Материалом исследования послужили обезличенные событийные данные образовательной платформы, обрабатываемые разработанной автоматизированной системой аналитической обработки учебной активности. Входной набор событий содержит идентификатор учащегося, временную метку, предмет, идентификатор и тип задания, сложность, признак правильности ответа, набранный и максимальный балл, длительность выполнения, признак завершения и число попыток. Перед генерацией текста выполняются приведение типов, нормализация строк, удаление дубликатов и записей без обязательных

идентификаторов, обработка аномальных значений времени и числа попыток, а затем агрегация данных по учащемуся и периоду.

После предобработки рассчитывается набор показателей, который используется как единственный источник данных для языковой модели. В него входят число и доля завершенных заданий, точность ответов, средний балл, число активных дней, общее и среднее время занятий, среднее число попыток, показатели по предметам и интегральный индекс вовлеченности. В контрольном примере за период 28 дней было зарегистрировано 142 задания, из которых завершено 125; точность составила 0,83, средний балл – 79%, индекс вовлеченности – 0,78, суммарное время работы – 106,5 мин, из 28 дней рассматриваемого периода ученик проявлял учебную активность в 21 уникальный день. Предметный разрез включал математику, чтение и логику.

Запрос к LLM состоит из двух частей. Системная инструкция задает роль доброжелательного методиста, обязательную структуру ответа, русский язык, объем 180–300 слов и прямой запрет на использование сведений, отсутствующих во входных данных. Пользовательская часть содержит только рассчитанные показатели. Целевой отчет должен включать общий вывод, сильные стороны ребенка, зоны роста и практические рекомендации. Общая схема формирования результата представлена на рисунке 1.



Рисунок 1 – Схема формирования и оценки персонализированного отчета

В качестве базовой использовалась модель семейства LLaMA на 8 млрд параметров. Выбор локальной модели обусловлен необходимостью контролировать обработку образовательных данных и исключить обязательную передачу показателей учащихся во внешние коммерческие API. Для адаптации применялся instruction-tuning: каждый обучающий пример имел тот же формат, что и рабочий запрос, и включал системную инструкцию, структурированные показатели учащегося и эталонный отчет. Подобная организация обучающих примеров используется при предметной адаптации больших языковых моделей и позволяет закреплять требуемый формат ответа и специфику прикладной задачи [7, 8].

Параметрически эффективное дообучение выполнялось методом LoRA поверх квантованной базовой модели, то есть в конфигурации QLoRA. Базовые веса загружались в 4-битном представлении и оставались замороженными; обновлялись только низкоранговые адаптеры в проекциях механизма внимания. Такой подход соответствует принципам LoRA и QLoRA [4, 5] и позволяет снизить требования к памяти по сравнению с полным обновлением всех параметров модели. Использованные параметры обучения приведены в таблице 1.

Таблица 1. Параметры адаптации модели

Параметр	Значение
Базовая модель	LLaMA, 8 млрд параметров
Квантование базовых весов	4 бита
Ранг LoRA-адаптера	16
Коэффициент масштабирования	32
Dropout	0,05

Число эпох	3
Размер батча	16
Оптимизатор	AdamW
Вычислительная среда	1 GPU, 24 ГБ VRAM

Для оценки текстов использовалась комбинированная система метрик. Coverage характеризует полноту отражения обязательных смысловых аспектов: общего вывода, сильных сторон, зон роста, рекомендаций, вовлеченности, точности, предметного разреза и времени занятий. Аспект считается отраженным при наличии соответствующего лексического маркера либо достаточного семантического сходства с эталонной формулировкой.

Faithfulness оценивает числовую достоверность и рассчитывается как доля числовых утверждений текста, подтверждаемых исходными показателями. При сопоставлении применяется относительный допуск 5 % или абсолютный допуск 1,0. Эта метрика непосредственно контролирует появление числовых «галлюцинаций», поскольку любое число в отчете должно быть связано с входным набором данных.

Distinct-N используется для оценки лексического разнообразия и рассчитывается как доля уникальных N-грамм среди всех N-грамм текста. В эксперименте применялись Distinct-1 и Distinct-2. Format compliance отражает выполнение трех формальных условий: объем 180–300 слов, наличие не менее двух абзацев и отсутствие markdown-разметки. Для сравнения с редакционным эталоном применялись ROUGE-1 и ROUGE-2, основанные на пересечении N-грамм кандидата и эталонного текста [6]. Количественная оценка дополнялась экспертной проверкой редакционной командой, состоявшей из трех редакторов образовательного контента, отвечающих за подготовку материалов и коммуникацию с внешними пользователями образовательной платформы.

Экспериментальная схема представляла собой контролируемое сравнение «до/после»: один и тот же набор структурированных показателей передавался базовой модели и модели после QLoRA-адаптации, после чего оба текста оценивались одинаковым набором метрик. Такой дизайн позволяет непосредственно оценить влияние предметной адаптации на конкретный сценарий генерации. В то же время эксперимент носит пилотный характер: в исходной работе не фиксировался статистически репрезентативный тестовый корпус, поэтому полученные значения интерпретируются как результат контрольного сценария, а не как оценка генеральной совокупности всех возможных отчетов.

Результаты и их обсуждение

До адаптации базовая модель в целом воспроизводила требуемую тематику отчета, однако не обеспечивала достаточную фактическую надежность. Coverage составила 0,88, что означает отсутствие части обязательных смысловых элементов. Faithfulness оказалась равной 0,80: не все числовые утверждения могли быть подтверждены входными показателями. Формальное соответствие структуре оценено в 0,67. Несмотря на относительно высокое лексическое разнообразие, текст не прошел редакционную проверку именно из-за риска недостоверных утверждений.

После QLoRA-дообучения все контролируемые критерии достигли требуемых значений. Сводное сравнение приведено в таблице 2.

Таблица 2. Сравнение качества текста до и после адаптации

Метрика	Базовая модель	После QLoRA	Изменение
Coverage	0,88	1,00	+0,12
Faithfulness	0,80	1,00	+0,20

Distinct-1	0,81	0,85	+0,04
Distinct-2	0,87	1,00	+0,13
Format compliance	0,67	1,00	+0,33
ROUGE-1 (F1)	0,40	0,59	+0,19
ROUGE-2 (F1)	0,13	0,22	+0,09
Экспертная оценка	не одобрено	одобрено	—

Наиболее значимым результатом является рост Faithfulness с 0,80 до 1,00. Для рассматриваемой прикладной задачи эта метрика важнее простой текстовой близости к эталону. Родительский отчет может быть стилистически удачным, но оставаться неприемлемым, если содержит придуманные проценты, длительности или сравнения. Достижение значения 1,00 в контрольном сценарии означает, что все обнаруженные числовые утверждения были согласованы с исходными показателями.

Рост Coverage до 1,00 показывает, что адаптированная модель устойчивее воспроизводит заданную композицию отчета. В отличие от универсального генеративного ответа, текст должен не только быть связным, но и последовательно закрывать продуктовые требования: дать общий вывод, указать сильные стороны, обозначить зоны роста и предложить рекомендации. Улучшение Format compliance с 0,67 до 1,00 подтверждает, что instruction-tuning помогает закрепить не только тематику, но и формальные ограничения.

ROUGE-1 F1 вырос с 0,40 до 0,59, ROUGE-2 F1 — с 0,13 до 0,22. Поскольку ROUGE измеряет совпадение N-грамм с эталоном [6], рост этих показателей свидетельствует о большей близости адаптированной модели к редакционному стилю. При этом ROUGE не следует использовать как единственный показатель качества персонализированного отчета: дословное копирование эталонных формулировок противоречило бы задаче сохранения естественной вариативности. По этой причине в работе одновременно используются Distinct-N и предметно ориентированные метрики Coverage и Faithfulness.

Distinct-1 увеличилась с 0,81 до 0,85, а Distinct-2 — с 0,87 до 1,00. В контрольном примере это не выявило признаков деградации текста в сторону механического повторения шаблона. Совместный рост ROUGE и Distinct-N можно интерпретировать как приближение к редакционной норме без потери лексического разнообразия. Финальный текст после дообучения получил одобрение редакционного подразделения, тогда как исходная версия одобрена не была.

С инженерной точки зрения, выбранный способ адаптации согласуется с ограничениями локального развертывания. LoRA не требует обновления всех весов модели [4], а 4-битная квантизация QLoRA дополнительно уменьшает объем памяти, необходимый для обучения [5]. В проведенной работе дообучение выполнялось на GPU с 24 ГБ видеопамяти, что подтверждает практическую ценность подхода при отсутствии специализированного многопроцессорного кластера.

Рассматриваемая схема отделяет вычисление образовательных показателей от их текстовой интерпретации. Все числовые значения, на основе которых генерируется отчет, формируются детерминированным аналитическим модулем, после чего языковая модель получает уже проверенные данные. За счет этого граница ответственности компонентов становится явной, а Faithfulness можно контролировать автоматически.

Основным ограничением проведенного эксперимента является его пилотный масштаб, из-за чего полученные численные изменения нельзя распространять на все возможные профили учащихся без дополнительного исследования.

Дальнейшим направлением развития может стать сравнение результата дообучения с prompt-only подходом, которое позволит оценить, в каких сценариях дополнительное

обучение экономически оправдано и дает лучшие результаты в сравнении с доработкой системной инструкции.

Заключение

В работе предложен способ адаптации локальной большой языковой модели к задаче генерации персонализированных отчетов об учебной активности учащихся. Исходные события образовательной платформы предварительно обрабатываются детерминированным аналитическим модулем, который рассчитывает показатели успеваемости, регулярности и вовлеченности. Языковая модель используется на следующем этапе только для текстовой интерпретации этих показателей.

Для предметной адаптации LLaMA-модели с 8 млрд параметров применено QLoRA-дообучение: базовые веса загружались в 4-битном представлении и оставались замороженными, а обучались низкоранговые LoRA-адаптеры. В контрольном эксперименте после адаптации Coverage и Faithfulness достигли 1,00, Format compliance увеличилась до 1,00, ROUGE-1 F1 — до 0,59, ROUGE-2 F1 — до 0,22. Итоговый текст получил положительную экспертную оценку редакционной команды.

Полученный результат показывает, что параметрически эффективное дообучение может использоваться для закрепления предметных и редакционных требований к отчетам при сохранении локального развертывания модели. Вместе с тем для статистически обоснованного вывода о величине эффекта требуется расширить эксперимент на независимый тестовый корпус и провести многократную оценку генераций. Разработанный подход может служить основой для дальнейшего исследования автоматизированной персонализированной отчетности в образовательных системах.

Список литературы:

1. Siemens G. Learning Analytics: The Emergence of a Discipline // American Behavioral Scientist. 2013. Vol. 57, No. 10. P. 1380–1400. DOI: 10.1177/0002764213498851.
2. Ferguson R. Learning analytics: drivers, developments and challenges // International Journal of Technology Enhanced Learning. 2012. Vol. 4, No. 5/6. P. 304–317. DOI: 10.1504/IJTEL.2012.051816.
3. Grattafiori A., Dubey A., Jauhri A. et al. The Llama 3 Herd of Models [Электронный ресурс]. 2024. arXiv:2407.21783. DOI: 10.48550/arXiv.2407.21783.
4. Hu E. J., Shen Y., Wallis P. et al. LoRA: Low-Rank Adaptation of Large Language Models // International Conference on Learning Representations (ICLR). 2022.
5. Dettmers T., Pagnoni A., Holtzman A., Zettlemoyer L. QLoRA: Efficient Finetuning of Quantized LLMs // Advances in Neural Information Processing Systems. 2023. Vol. 36. P. 10088–10115. DOI: 10.52202/075280-0441.
6. Lin C.-Y. ROUGE: A Package for Automatic Evaluation of Summaries // Text Summarization Branches Out. Barcelona: Association for Computational Linguistics, 2004. P. 74–81.
7. Рашка С. Строим LLM с нуля. СПб.: Питер, 2025. 384 с. ISBN 978-5-4461-4325-2.
8. Ozdemir S. Quick Start Guide to Large Language Models: Strategies and Best Practices for ChatGPT, Embeddings, Fine-Tuning, and Multimodal AI. 2nd ed. Addison-Wesley Professional, 2024. 384 p. ISBN 978-0-13-534656-3.

References:

1. Siemens G. Learning Analytics: The Emergence of a Discipline. *American Behavioral Scientist*, 2013, vol. 57, no. 10, pp. 1380–1400. DOI: 10.1177/0002764213498851.
2. Ferguson R. Learning analytics: drivers, developments and challenges. *International Journal of Technology Enhanced Learning*, 2012, vol. 4, no. 5/6, pp. 304–317. DOI: 10.1504/IJTEL.2012.051816.
3. Grattafiori A., Dubey A., Jauhri A. et al. The Llama 3 Herd of Models. 2024. arXiv:2407.21783. DOI: 10.48550/arXiv.2407.21783.
4. Hu E. J., Shen Y., Wallis P. et al. LoRA: Low-Rank Adaptation of Large Language Models. *International Conference on Learning Representations (ICLR)*, 2022.
5. Dettmers T., Pagnoni A., Holtzman A., Zettlemoyer L. QLoRA: Efficient Finetuning of Quantized LLMs. *Advances in Neural Information Processing Systems*, 2023, vol. 36, pp. 10088–10115. DOI: 10.52202/075280-0441.
6. Lin C.-Y. ROUGE: A Package for Automatic Evaluation of Summaries. In: *Text Summarization Branches Out*. Barcelona: Association for Computational Linguistics, 2004, pp. 74–81.
7. Raschka S. *Stroim LLM s nulya [Build a Large Language Model (From Scratch)]*. St. Petersburg: Piter, 2025. 384 p. ISBN 978-5-4461-4325-2. (In Russian).
8. Ozdemir S. *Quick Start Guide to Large Language Models: Strategies and Best Practices for ChatGPT, Embeddings, Fine-Tuning, and Multimodal AI*. 2nd ed. Addison-Wesley Professional, 2024. 384 p. ISBN 978-0-13-534656-3.