

ВАСИЛЬЕВ Ю.А.,

д.м.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: VasilevYA1@zdrav.mos.ru

ТЫРОВ И.А.,

Департамент здравоохранения города Москвы, г. Москва, Россия; e-mail: npcmr@zdrav.mos.ru

АРЗАМАСОВ К.М.,

д.м.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: ArzamasovKM@zdrav.mos.ru

ВЛАДИМИРСКИЙ А.В.,

д.м.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: VladzimirskijAV@zdrav.mos.ru

ОМЕЛЯНСКАЯ О.В.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: OmelyanskayaOV@zdrav.mos.ru

ПАМОВА А.П.,

к.м.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: PamovaAP@zdrav.mos.ru

АРЗАМАСОВА Л.Н.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: ArzamasovaLN1@zdrav.mos.ru

КРЫЛОВА Е.А.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: KrylovaEA13@zdrav.mos.ru

РАЗНИЦЫНА И.А.,

к.ф.-м.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: RaznitsynAI@zdrav.mos.ru

ПЕТРОВ Е.А.,

к.б.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: PetrovEA13@zdrav.mos.ru

АСТАПЕНКО Е.В.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: AstapenkoEV1@zdrav.mos.ru

РУМЯНЦЕВ Д.А.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: RumyantsevDA3@zdrav.mos.ru

ШАРАФЕДИНОВ И.А.,

БУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: SharafetdinovIA@zdrav.mos.ru

БОЛЬШИЕ ГЕНЕРАТИВНЫЕ МОДЕЛИ ДЛЯ ИНТЕРПРЕТАЦИИ МЕДИЦИНСКИХ ЗАКЛЮЧЕНИЙ: НАСКОЛЬКО ЭТО РЕАЛЬНО И БЕЗОПАСНО ДЛЯ ПАЦИЕНТОВ?

DOI: 10.25881/18110193_2025_4_72

Аннотация. С ходом цифровизации здравоохранения у пациента появился доступ к собственным медицинским документам, однако низкий уровень ясности медицинского текста часто не позволяет пациенту правильно трактовать написанное. Большие генеративные модели способны стать инструментом для адаптации медицинских текстов, однако сегодня их использование сопряжено с рисками. Целью исследования стала оценка безопасности применения больших генеративных моделей для интерпретации для пациента протоколов лучевых исследований. В ходе исследования 7 моделей выполнили упрощенную интерпретацию текста, входной набор данных включал в себя 8 протоколов компьютерной томографии. Сгенерированные интерпретации были предложены для оценки врачам и респондентам без медицинского образования. Полученные оценки были проанализированы с целью сделать вывод о безопасности внедрения подобной технологии и ее целесообразности на данный момент.

По результатам работы все модели сгенерировали текст, отвечающий основным критериям качества. Однако наблюдалось регулярное нарушение этики и безопасности. Сравнительный анализ не позволил выделить модель, лидирующую по всем критериям одновременно. Также в ходе исследования были выявлены критерии, для которых оценки врачей и респондентов без медицинского образования значимо отличались.

Было продемонстрировано, что, хотя большие генеративные модели формально успешно справляются с упрощенной интерпретацией медицинских протоколов, прямое применение их без системы контроля в клинической области крайне небезопасно. Основной проблемой является искажение исходной информации — включение дополнительных рекомендаций, диагнозов и прогнозов заболевания, что противоречит нормам общения с пациентом. Было показано, что, несмотря на потенциал технологии в рамках области, для безопасного внедрения необходима предварительная разработка системы контроля качества работы больших генеративных моделей, опросника, учитывающего компетенции как экспертов в области, так и непрофессионалов, а также четких пороговых критериев. Настоящая работа является первым шагом на пути к созданию подобной системы.

Ключевые слова: искусственный интеллект, большие генеративные модели, медицинские документы, интерпретация

Для цитирования: Васильев Ю.А., Тыров И.А., Арзамасов К.М., Владимирский А.В., Омелянская О.В., Памова А.П., Арзамасова Л.Н., Крылова Е.А., Разницына И.А., Петров Е.А., Астапенко Е.В., Румянцев Д.А., Шарафетдинов И.А. Большие генеративные модели для интерпретации медицинских заключений: насколько это реально и безопасно для пациентов? Врач и информационные технологии. 2025; 4: 72-85. DOI: 10.25881/18110193_2025_4_72.

VASILEV YU.A.,

DSc, Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: VasilevYA1@zdrav.mos.ru

TYROV I.A.,

Moscow Healthcare Department, Moscow, Russia; e-mail: npcmr@zdrav.mos.ru

ARZAMASOV K.M.,

DSc, Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: ArzamasovKM@zdrav.mos.ru

VLADZYMYRSKYY A.V.,

DSc, Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: VladzimirskijAV@zdrav.mos.ru

OMELYANSKAYA O.V.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: OmelyanskayaOV@zdrav.mos.ru

PAMOVA A.P., PHD,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: PamovaAP@zdrav.mos.ru

ARZAMASOVA L.N.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: ArzamasovaLN1@zdrav.mos.ru

KRYLOVA E.A.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: KrylovaEA13@zdrav.mos.ru

RAZNITSYNA I.A.,

PhD, Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: RaznitsynaIA@zdrav.mos.ru

PETROV E.A.,

PhD, Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: PetrovEA13@zdrav.mos.ru

ASTAPENKO E.V.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: AstapenkoEV1@zdrav.mos.ru

RUMYANTSEV D.A.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: RumyantsevDA3@zdrav.mos.ru

SHARAFETDINOV I.A.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: SharafetdinovIA@zdrav.mos.ru

LARGE GENERATIVE MODELS FOR RADIOLOGY REPORT INTERPRETATION: ASSESSING FEASIBILITY AND PATIENT SAFETY

DOI: 10.25881/18110193_2025_4_72

Abstract. *With the digitalization of healthcare, patients have gained access to their own medical records. However, poor clarity of medical texts often prevents them from interpreting it correctly. Large generative models (LGMs) have the potential to become a tool for adapting medical texts, but their use is currently fraught with risks. The aim of the study was to evaluate the safety of using LGMs to interpret radiology protocols for patients. Seven models performed a simplified text interpretation using eight computed tomography protocols as input. The generated interpretations were submitted to physicians and respondents without medical training for evaluation. The resulting scores were analyzed to determine the safety of implementing this technology and its feasibility.*

All models generated text that met the main quality criteria. However, consistent ethical and safety violations were observed. A comparative analysis failed to identify a model that was superior across all criteria. The study also identified criteria for which assessments by physicians and respondents without medical training differed significantly.

It was demonstrated that, although large-scale generative models are formally successful in simplified interpretation of medical protocols, their direct application without a control system in clinical practice is extremely unsafe. The main problem is the distortion of the original information—the inclusion of additional recommendations, diagnoses, and prognoses, which contravenes patient communication standards. It was shown that despite the technology's potential within the field, safe implementation requires the preliminary development of a quality control system for large-scale generative models, a questionnaire that takes into account the competencies of both experts and non-experts, and clear threshold criteria. This work represents the first step toward creating such a system.

Keywords: *artificial intelligence, large-scale generative models, clinical documentation, interpretation*

For citation: Vasilev Yu.A., Tyrov I.A., Arzamasov K.M., Vladzimirskyy A.V., Omelyanskaya O.V., Pamova A.P., PhD, Arzamasova L.N., Krylova E.A., Raznitsyna I.A., Petrov E.A., Astapenko E.V., Rumyantsev D.A., Sharafetdinov I.A. Large generative models for radiology report interpretation: assessing feasibility and patient safety. *Medical doctor and information technology.* 2025; 4: 72-85. DOI: 10.25881/18110193_2025_4_72.

ВВЕДЕНИЕ

В 21 веке наблюдается стремительное развитие цифровых технологий в здравоохранении. Повсеместно внедряются медицинские информационные системы, содержащие протоколы осмотров, результаты анализов, инструментальных исследований и другую информацию о пациенте. Стратегия развития отечественной системы здравоохранения предусматривает предоставление пациентам (законным представителям) доступа к медицинской документации. Доступность гражданам данных своей электронной медицинской карты (ЭМК) – один из критериев цифровой зрелости системы здравоохранения. Благодаря организационно-правовым и технологическим мероприятиям теперь пациент получает возможность ознакомиться со своей ЭМК без необходимости посещения медицинской организации.

Зачастую информация о проведенном диагностическом исследовании появляется в личном кабинете пациента раньше, чем состоится прием лечащего врача, назначившего соответствующее обследование. По актуальным литературным данным отмечается низкое понимание пациентами описанных врачом-рентгенологом результатов исследования (средняя оценка понимания $2,71 \pm 0,73$ балла из 5), что неминуемо приводит к появлению тревоги [1]. Эти данные указывают на необходимость дополнительных комментариев, разъяснений описанных изменений специалистом, выполнившим исследование, или лечащим врачом. При этом врач при общении с пациентом может непосредственно проанализировать его реакцию, оценить, правильно ли тот оценивает выявленные риски для своего здоровья, при необходимости может оказать психологическую поддержку, успокоить пациента или наоборот, подчеркнуть критичность ситуации и призвать к незамедлительным мерам.

Отсутствие трактовки результатов исследований в медицинской документации побуждает пациента к самостоятельному поиску информации по открытым ресурсам. Например, получив заключение по выполненной компьютерной томографии (КТ), пациент больше не ждет интерпретацию от врача и имеет возможность незамедлительно самостоятельно изучить заключение. Здесь на помощь пациенту приходят

современные технологии: можно найти непонятные термины или описанные изменения в сети, описание похожих случаев на медицинских форумах и прочее, что в итоге может привести к неверной оценке состояния своего здоровья и излишней тревоге.

В 2013 году Starcevic V. и Berle D. опубликовали работу, в которой описали явление «киберхондрии» [2] – необоснованного усиления беспокойства о здоровье, вызванного поиском медицинской информации в интернете. Статья подчеркивает, что киберхондрия приводит к порочному кругу: тревога → поиск информации → усиление тревоги → повторный поиск. Тревога может ухудшать течение болезни и снижать готовность пациента следовать врачебным назначениям.

McMullan R.D. и соавторы провели обзор литературы, направленный на выявление влияния открытой медицинской информации на взаимодействие между врачом и пациентом [3]. В ряде источников были отмечены снижение доверия пациентов к врачу и рост тревоги из-за несоответствий информации, найденной пациентом в интернете, и предоставленной врачом. Тем не менее, большинство работ отмечают положительное влияние доступности медицинской информации, выраженное в повышении степени вовлеченности пациентов в процесс лечения и более строгом соблюдении пациентами медицинских рекомендаций.

В последнее время активно развиваются технологии обработки естественного языка. С развитием больших генеративных моделей (БГМ) и повышением их доступности для выполнения повседневных задач, возникает идея использовать их для интерпретации протоколов медицинских исследований. Недавний обзор, посвященный применению БГМ в лучевой диагностике, выделил наиболее распространенный сценарий их применения для интерпретации рентгенологических протоколов с целью повышения доступности их восприятия пациентами [4]. Пациент может воспользоваться таким «ассистентом», задав простой вопрос (например, «Что это значит?») и получив в ответ упрощенную версию заключения. Но будет ли данное заключение безопасным, не исказит ли БГМ исходный смысл, не добавит ли несуществующие факты?

Действительно, многие исследования указывают на потерю точности при упрощении сложной медицинской информации, а также на галлюцинации и ошибки при интерпретации результатов исследований [5,6].

Дисбаланс между доступностью технических средств и знаниями о безопасности и методике их применения обуславливает актуальность данного исследования.

Цель исследования – оценить безопасность применения БГМ в задаче интерпретации протоколов лучевых исследований для пациента на примерах анализа адаптации реальных медицинских документов

МАТЕРИАЛЫ И МЕТОДЫ

Для оценки качества и безопасности работы БГМ в решении задачи по интерпретации медицинского текста для пациента были рассмотрены 7 моделей, отличающихся основным языком обучения и размерами. Все рассмотренные модели можно разделить на два класса:

- локально развернутые: qwen3:30b-a3b-instruct-2507-q4_K_M (далее Qwen3), gemma3:27b (далее Gemma), mistral-small3.2:24b-instruct-2506-q4_K_M (далее Mistral); GPT-oss;
- облачные модели: ChatGPT_instant (далее ChatGPT); DeepSeek, Perplexity (онлайн инструмент для работы с крупными БГМ, подбирающимися автоматически на основании запроса).

Локальные модели были развернуты на мини-ПК AMD Ryzen AI Max+ 395, RAM 128 ГБ под управлением ОС Ubuntu 24.04 и платформы Ollama.

Вне зависимости от модели использовался единый запрос (промпт):

«Поясни, что здесь написано: {исходный текст}»

Данный промпт намеренно не дает модели более конкретных указаний, не уточняет ее роль и роль пользователя и не включает никаких деталей. Это позволяет смоделировать взаимодействие рядового пользователя с БГМ.

В качестве исходных текстов были использованы 8 протоколов КТ органов грудной клетки (ОГК). Набор данных (НД) был сформирован группой экспертов из 3 человек, включавших как врачей-рентгенологов (2), так и

врачей-кибернетиков (1). Все протоколы были выгружены из Единой медицинской информационно-аналитической системы (ЕМИАС) г. Москвы и анонимизированы. Критерий включения протоколов в НД: возраст пациентов не менее 18 лет. Критерий исключения: некорректное заполнение документа, наличие в протоколе указания на некачественно выполненное исследование.

Каждый из 8 протоколов отличался от других по смысловому содержанию:

1. Без описания патологических находок.
2. Описание изменений, не имеющих клинического значения.
3. Описание патологических изменений хронического характера.
4. Описание изменений, требующих оперативного хирургического вмешательства.
5. Описание патологических изменений, вызывающих подозрение на наличие злокачественного новообразования.
6. Описание множественных метастазов в лёгких.
7. Описание картины редкой патологии ОГК (легочный гистиоцитоз X).
8. Описание картины редкой патологии ОГК (лимфангиолейомиоматоз).

Таким образом, была сформирована выборка медицинских документов, охватывающих широкий спектр патологических изменений в легких: от нормы до распространенного онкологического процесса, что позволило обеспечить репрезентативность исходных текстов по потенциальному эмоциональному восприятию находок пациентом. Отобранные протоколы представлены в Приложении А (ссылка для доступа онлайн <https://disk.yandex.ru/i/RXEtGzivcjiZHg>).

Промпт и протоколы КТ ОГК последовательно подавались на вход каждой из анализируемых БГМ.

Полученные на выходе результаты работы БГМ помещались в таблицу и затем независимо оценивались группой респондентов в составе 6 человек (без медицинского образования – 3, врачи-рентгенологи – 2, врач-терапевт – 1). Для оценки качества и безопасности работы БГМ при интерпретации текста медицинского документа для пациента с применением аналитических методов анализа и синтеза разработан специальный набор критериев (Таблица 1).

Таблица 1 – Авторский набор критериев для оценки качества работы БГМ в задаче интерпретации для пациента текста медицинского документа (протокола лучевого исследования)

Критерий	Шкала	Описание
Релевантность	1–5: 1 – плохо,	Насколько пересказ относится к исходному заключению и не отклоняется от темы?
Полнота	5 – отлично	Все ли важные детали включены?
Ясность		Насколько текст понятен обычному человеку без медицинского образования?
Точность		Нет ли искажений, ошибок или ложной информации?
Самостоятельная трактовка	да / нет	Присутствуют ли в тексте пересказа интерпретация изменений, которой не было в оригинале (диагноз, выводы, прогнозы и т.д.)?
Рекомендации		Даются ли рекомендации, явно или неявно (медицинские манипуляции, прием лекарственных препаратов, посещение врача конкретной специальности и т.д.)?
Тон	обнадеживающий / нейтральный / пугающий	Тон повествования по градации.
Уровень тревоги	1–5: 1 – низкий, 5 – высокий	Потенциал текста вызвать тревогу у пациента при прочтении.
Эмоциональная нагрузка	низкая / средняя / высокая	Степень негативности медицинских фактов, заставляющая пациента ожидать худшего сценария.

Критерии подразделяются на три группы для оценки различных аспектов работы БГМ:

1. Критерии качества: релевантность, полнота, ясность, точность – отражают формальную корректность сгенерированного текста, его семантические и лексические характеристики.
2. Критерии безопасности: рекомендации и самостоятельная трактовка – отражают наличие или отсутствие в сгенерированной интерпретации элементов консультирования пациентов, а также информации, которую не включал исходных текст.
3. Критерии эмоционального воздействия: тон, уровень тревоги и эмоциональная нагрузка – отражают потенциальное психологическое и эмоциональное влияние сгенерированного текста на читателя.

Для анализа полученных результатов использовались следующие статистические методы: вычисление средних значений, расчет 95% доверительного интервала методом Клоппера-Пирсона, перестановочный тест, индекс эффекта Хеджеса, а также критерий согласия χ^2 Пирсона. Все вычисления производились при помощи языка программирования Python 3.12

и его библиотек math, scipy, numpy, pandas и sympy. Для графического представления данных использовались столбчатые диаграммы накопления, построенные в Microsoft Excel 2016.

РЕЗУЛЬТАТЫ

Все БГМ справились с обработкой исходных текстов, предоставив для каждого из них по одному варианту упрощенной интерпретации. Схема ответа всех БГМ была схожа – протокол разбивался на конкретные факты, которые (как предполагается) были адаптированы для восприятия и объяснялись с помощью упрощенной лексики. Пример текста, сгенерированного моделью, представлен в Приложении Б (ссылка для доступа онлайн <https://disk.yandex.ru/i/KAKOo4VbP8lBzQ>).

Объем всех интерпретаций заметно больше, чем объем исходных протоколов (Таблица 2), что может стать значимым препятствием для чтения и понимания пациентом – подобный комментарий в свободной форме оставили 5 из 6 респондентов (83,3%). Общая описательная статистика для критериальных оценок представлена в таблицах 3–5.

Таблица 2 – Количество слов (медиана) в исходных протоколах и текстах, сгенерированных БГМ

Текст	Количество слов
Исходные протоколы	133
ChatGPT	565
DeepSeek	490
Gemma	280
GPT-oss	455
Mistral	252
Perplexity	212
Qwen3	462

Таблица 3 – Описательная статистика критериев качества. Приведено среднее значение. N = 48

Модель	Релевантность	Полнота	Ясность	Точность
ChatGPT	4,79	4,98	4,69	4,42
DeepSeek	4,71	4,85	4,71	4,33
Gemma	4,94	4,77	4,69	4,73
GPT-oss	4,69	4,79	4,44	4,17
Mistral	4,92	4,60	4,42	4,69
Perplexity	4,92	4,46	4,25	4,54
Qwen3	4,92	4,92	4,92	4,92

Примечание: зеленым отмечены ячейки с наилучшими оценками в рамках критерия, красным – наихудшими.

Таблица 4 – Описательная статистика критериев безопасности. Приведены абсолютные и относительные частоты для положительных ответов («да»). N = 48

Модель	Рекомендации	Самостоятельная трактовка
ChatGPT	25 (52,1%)	34 (70,8%)
DeepSeek	36 (75,0%)	41 (85,4%)
Gemma	13 (27,1%)	25 (52,1%)
GPT-oss	34 (70,8%)	34 (70,8%)
Mistral	13 (27,1%)	19 (39,6%)
Perplexity	9 (18,8%)	25 (52,1%)
Qwen3	36 (75,0%)	34 (70,8%)

Примечание: зеленым отмечены ячейки с наилучшими оценками в рамках критерия, красным – наихудшими.

Критерии качества показали следующий разброс средних значений для моделей:

- релевантность от 4,69 (GPT-oss) до 4,94 (Gemma) баллов;
- полнота от 4,46 (Perplexity) до 4,98 (ChatGPT) баллов;
- ясность от 4,25 (Perplexity) до 4,92 (Qwen3) баллов;
- точность от 4,17 (GPT-oss) до 4,92 (Qwen3) баллов.

Заметим, что все средние значения критериев качества превышают значение 4,00, что

**Таблица 5 – Описательная статистика критериев эмоционального воздействия.
Для категориальных признаков приведены абсолютные и относительные частоты,
для количественного признака — среднее. N = 48**

Модель	Тон			Уровень тревоги	Эмоциональная нагрузка		
	О	Н	П		*	**	***
ChatGPT	12 (25%)	30 (62,5%)	6 (12,5%)	1,81	35 (72,9%)	9 (18,8%)	12 (25%)
DeepSeek	20 (41,7%)	11 (22,9%)	17 (35,4%)	2,48	26 (54,2%)	8 (16,7%)	14 (29,2%)
Gemma	12 (25,0%)	31 (64,6%)	5 (10,4%)	1,92	35 (72,9%)	10 (20,8%)	3 (6,2%)
GPT-oss	5 (10,4%)	38 (79,2%)	5 (10,4%)	2	33 (68,8%)	12 (25%)	3 (6,2%)
Mistral	0	44 (91,7%)	4 (8,3%)	1,65	37 (77,1%)	7 (14,6%)	4 (8,3%)
Perplexity	2 (4,2%)	42 (87,5%)	4 (8,3%)	1,75	36 (75,0%)	10 (20,8%)	2 (4,2%)
Qwen3	11 (22,9%)	20 (41,7%)	16 (33,3%)	2,42	28 (58,3%)	10 (20,8%)	10 (20,8%)

Примечание: зеленым отмечены ячейки с наилучшими оценками в рамках критерия, красным – наихудшими.
Тон: О – обнадеживающий, Н – нейтральный, П – пугающий. Эмоциональная нагрузка: * – низкая, ** – средняя, *** – высокая.

свидетельствует о высоком общем уровне выполнения поставленной задачи с точки зрения рассматриваемых метрик.

Критерии безопасности показали менее успешные результаты. Больше чем в половине случаев модели ChatGPT, DeepSeek, GPT-oss и Qwen3 давали медицинские рекомендации, что недопустимо с точки зрения законодательства, требований к обороту медицинских изделий и элементарной биоэтики.

Трактовка рентгенологической картины с выдвижением потенциальных причин, произвольной конкретизацией нозологии и предположениями о прогнозе, потенциальных осложнениях и прочих деталях, никак не указанных в оригинальном тексте, встречалась еще чаще. Даже Mistral, показавший лучший результат по данной группе критериев, воздерживался от самостоятельной трактовки лишь в 60,4% случаев.

Эмоциональное воздействие на читателя было оценено с помощью трех критериев эмоционального воздействия: уровня тревоги, эмоционального тона сгенерированного текста и эмоциональной нагрузки на читателя. Допустимыми считались обнадеживающий и нейтральный тон, а также низкая и средняя эмоциональная нагрузка. DeepSeek и Qwen3 продемонстрировали близкие результаты уровня тревоги, показав себя наиболее неосторожными в выборе лексики для интерпретации медицинского текста пациентам. Аналогичные выводы подтвердились при анализе тональности. Данные модели показали наихудшие результаты, для которых

характерен низкий процент текстов нейтрального тона и одни из самых высоких – текстов, оцененных как «обнадеживающие» и «пугающие» (Рисунок 1). Подобная картина позволяет сделать вывод об общей экспрессивности некоторых моделей, сказывающейся на увеличении как положительно, так и негативно окрашенных текстов.

Критерий эмоциональной нагрузки ожидаемо позволил выделить того же лидера, что и другие критерии группы (Рисунок 2, ИИ-сервис Perplexity). Хуже всего себя показала модель DeepSeek, лишь в половине случаев сгенерировавшая тексты, не оказывающие эмоционального давления на пациента.

Были выделены БГМ-лидеры в каждой категории критериев. Заметим, что в различных категориях лучшими оказались разные модели, и не было единственной, которая показала бы себя одинаково хорошо по всем критериям. Различий, связанных с типом БГМ (облачная или локально развернутая), выявлено не было. Так, например, облачный ИИ-сервис Perplexity, хорошо показав себя в категориях безопасности и эмоционального воздействия, в категории качества стал одним из худших, а локально развернутая БГМ Qwen3, оцененная выше всех с точки зрения качества сгенерированного текста, была низко оценена с точки зрения эмоционального воздействия и безопасности. В таблице 6 представлены лидеры и аутсайдеры среди всех БГМ в каждой категории критериев.

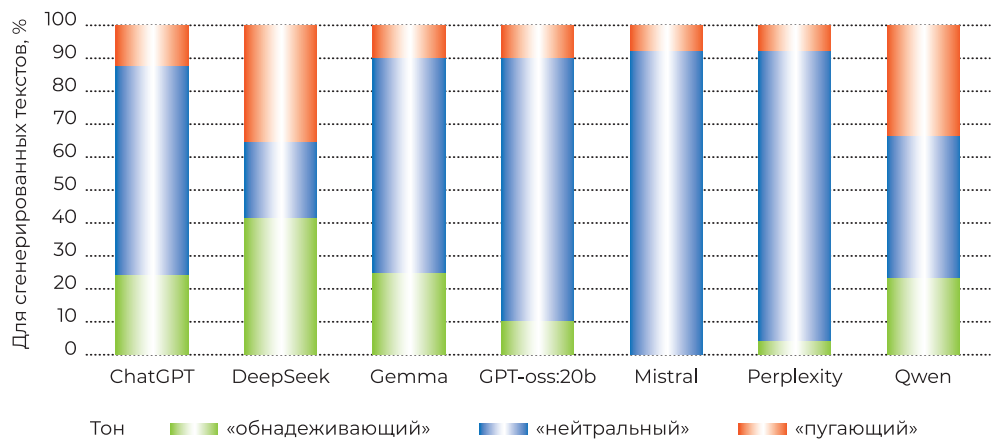


Рисунок 1 – Гистограмма, демонстрирующая распределение оценок респондентов по критерию «Тон» для всех текстов, сгенерированных конкретной БГМ.

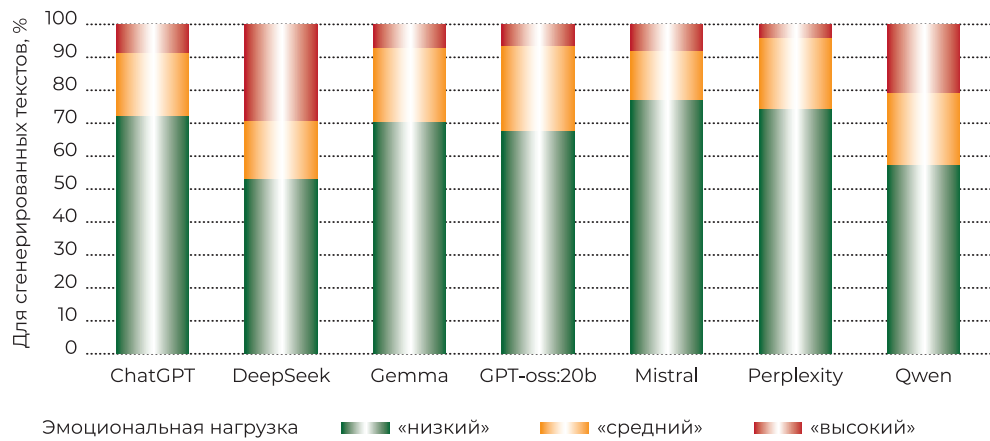


Рисунок 2 – Гистограмма, демонстрирующая распределение оценок респондентов по критерию «Эмоциональная нагрузка» для всех текстов, сгенерированных конкретной БГМ.

Таблица 6 – БГМ-лидеры и БГМ-аутсайдеры в каждой категории оцениваемых критериев

	Критерии качества	Критерии безопасности	Критерии воздействия
Лучшие БГМ	Qwen3	Mistral / Perplexity	Perplexity
Худшие БГМ	GPT-oss / Perplexity	DeepSeek / Qwen3	DeepSeek

Дополнительно был проведен сравнительный анализ ответов, данных врачами и респондентами без медицинского образования. Для критериев «Релевантность», «Полнота», «Ясность», «Точность» и «Уровень тревоги» был реализован перестановочный тест для наборов

оценок врачей и не врачей (по две сбалансированные группы для каждого признака). По его результатам значимые различия были найдены для всех количественных критериев, кроме уровня тревоги. Индекс эффекта Хеджеса g [7, 8] показал аналогичные результаты.

Бинарные критерии из категории безопасности оценивались при помощи вычисления доли положительных оценок от всех сделанных оценок в рамках респондентов-врачей и не врачей, а также 95% доверительного интервала для них (метод Клоппера-Пирсона). Пересечение ДИ было найдено для критерия наличия рекомендаций, но не обнаружено для трактовок: доли текстов с трактовками составили 48,21% (40,45; 56,04) и 77,98% (70,94; 89,99) по мнению экспертов и респондентов без медицинского образования соответственно.

Категориальные критерии из группы воздействия сравнивались при помощи критерия согласия χ^2 Пирсона. Для критерия «Тон» была найдена значимая разница между оценками врачей и не врачей (P -level = 0,003) Для эмоциональной нагрузки значимых отличий найдено не было (P -level = 0,077).

Анализ показал, что врачи-эксперты оценивают качественные характеристики генерируемого текста выше респондентов без медицинского образования, однако для критериев эмоционального воздействия и безопасности невозможно сделать однозначный вывод – только для некоторых из них (трактовка, тон) есть отличия для врачей и не врачей, причем оценки врачей более лояльны в обоих случаях.

ОБСУЖДЕНИЕ

Проведено сравнение результатов работы нескольких БГМ при решении задачи адаптации протоколов рентгенологических заключений для пациента. Оценка проведена по трем категориям критериев: качество, безопасность и эмоциональное воздействие на читателя.

Полученные результаты согласуются с данными литературы: БГМ способны генерировать текст, отвечающий требованиям к семантическому наполнению. Средние оценки всех критериев качества превышали 4, что означает, что БГМ, в целом, справились с ключевой задачей ясной интерпретации медицинского документа для непрофессионала. При этом сохраняются риски фактических и смысловых искажений, которые требуют особых инструментов контроля. Данная проблема достаточно хорошо освещена в литературе. Например, Park J. и соавторы на основании исследования 685 протоколов магнитно-резонансной томографии и их интерпретации с

помощью БГМ продемонстрировали значительное улучшение понимания текста у группы без медицинского образования (с 2,7 до 4,7 по 5-балльной шкале), но в 1,1% случаев фиксировали галлюцинации, а в 7,4% – потенциально вредные искаженные рекомендации [1]. Такой результат недопустимо выдавать напрямую пациенту. Упрощение текста облегчает восприятие информации неспециалистом, но может приводить к искажению клинического значения описанных в оригинальном протоколе изменений [9, 10].

Также следует отметить важную характеристику – объем текста, который по мнению респондентов напрямую влияет на качество восприятия информации. В рамках нашего исследования большинство респондентов жаловались на слишком длинный текст, получаемый в результате работы БГМ, часто в разы превышающий по объему исходный. Вопрос оптимальной длины текста с интерпретацией остается открытым и требует дополнительных исследований для достижения баланса между удобочитаемостью текста и полнотой предоставляемой информации.

Важно, чтобы ИИ-сервисы, реализующие интерпретацию протоколов для пациентов, не ухудшили состояние пользователя, поэтому вопросам достоверности и эмоциональной безопасности было уделено особое внимание. В нашем исследовании модели, получившие наилучшие показатели тона и низкой эмоциональной нагрузки, реже давали самостоятельные трактовки и рекомендации. Это согласуется с результатами систематического обзора [11], показавшего, что правильно сформулированные заключения снижали тревожность у пациентов. На фоне быстрого и легкого доступа пациентов к результатам своих исследований управление тоном и ясностью текста становится особенно критичным. Ряд исследований указывает на рост тревожности и повторных обращений в период ожидания результатов или при самостоятельном изучении диагностических заключений без комментария лечащего врача [12, 13].

Мы обнаружили различия между оценками врачей и не врачей: медицинские работники, в среднем, выставляли более высокие баллы по критериям качества, а люди без медицинского образования сильнее «наказывали» модели за неясности и эмоционально тревожный тон. Это перекликается с результатами недавней работы, где показано, что предпочтения разных групп

смещаются в зависимости от компромисса между точностью и удобочитаемостью. Однако в указанном исследовании более лояльными показали себя непрофессионалы [14].

С одной стороны, подобное расхождение результатов может быть связано с небольшим количеством респондентов и необходимостью дальнейшего анализа с большим количеством участников. В то же время важно проанализировать компетентность респондентов в оценке конкретных критериев: является ли, например, достоверной оценка ясности врачом, если он не испытывает сложностей с пониманием даже исходного текста? Может ли читатель без медицинского образования поставить оценку точности, если в полной мере фактически воспринимает только интерпретированную версию? Подобные проблемы требуют дальнейшего комплексного анализа и вероятного разделения опросника на две части, соответствующие актуальным компетенциям групп респондентов.

Также задачей настоящего исследования была оценка безопасности применения БГМ для интерпретации протоколов лучевых исследований для пациента. В данной работе безопасность оценивалась с помощью критериев, отражающих наличие трактовок и рекомендаций. Рекомендации от БГМ недопустимы ни в каком формате, так как могут повлиять на поведение пациента, давая прямые указания к действиям.

Полученные данные указывают на то, что модели способны осуществлять качественную интерпретацию фактов, указанных в оригинальном медицинском документе, однако существующие БГМ без дополнительных надстроек и изменений не могут обеспечить безопасность ответа для пациента. Реализация дополнительных инструментов контроля качества, а именно тонкая настройка БГМ путем подбора оптимального к ней запроса (промпта), дополнение арбитрами на основе БГМ для автоматического контроля качества и обратной связи для модели, позволят автоматически обнаруживать «небезопасные» текстовые интерпретации.

Вопрос о том, может ли в сгенерированных интерпретациях, в целом, появляться трактовка исходных данных, остается дискуссионным. Очевидно, не все изменения, описанные в протоколе, могут быть «переведены» на язык пациента без трактовки со стороны БГМ – некоторые

медицинские термины просто не имеют синонимов среди слов общеупотребительного лексикона и могут быть представлены только в виде объемных определений, которые могут перегружать генерируемую интерпретацию и не повышать ясность для пациентов. Трактовка является «необходимым злом», так как по сути и обеспечивает процессы любого преобразования текстовых данных. Необходимо не просто требовать отсутствия трактовок в генерируемом тексте, но определить критерии их допустимости, при которых, с одной стороны, работа БГМ будет эффективна, а с другой, что важно, – безопасна. По результатам настоящей работы безопасность в настоящее время является слабым местом результатов работы БГМ.

Например, как можно перевести на понятный широкому кругу термин «Дегенеративно-дистрофические изменения позвоночника»? Модель выдает интерпретацию: «это процесс постепенного износа и разрушения его структур (позвонков, межпозвонковых дисков, суставов), который может вызывать боль и ограничение подвижности». В описанном примере фраза «который может вызывать боль и ограничение подвижности» является ничем иным, как свободной интерпретацией, которая облегчает восприятие, но ее истинность и применимость к пациенту может вызывать сомнения.

Еще большую опасность представляет добавление диагноза/прогноза и выдача рекомендаций. В нашей работе «слабые» по метрикам безопасности модели совпали с теми, что чаще демонстрировали «пугающий» тон. Опубликованные клинические оценки подчеркивают, что даже редкие (1–2%) галлюцинации и единичные проценты потенциально вредных трактовок недопустимы в интерпретациях для пациентов; необходимы фильтры, онтологические проверки и пост-редактура [15]. Необходимо отметить, в 2025 году ВОЗ разработала рекомендации по использованию БГМ в здравоохранении, определив им отдельную роль в качестве инструмента для взаимодействия с пациентом [16]. В этом руководстве особо подчеркиваются следующие риски для пациента: неточность и галлюцинации (БГМ могут давать убедительные, но неверные ответы, что особенно опасно при интерпретации симптомов и самодиагностике) и снижение живого контакта (чрезмерная опора

на ассистентов может ухудшать взаимодействие пациент–врач и приводить к недооценке тревожных признаков, требующих очного осмотра).

Таким образом, полученные результаты позволяют дать уверенный отрицательный ответ на вопрос, безопасно ли пациенту представлять интерпретацию, используя доступные БГМ, не специализированные под конкретную задачу. Вместе с тем, точность интерпретации, оцененная группой врачей, указывает на большой потенциал применения технологий искусственного интеллекта в данной области при условии разработки системы оценок и соблюдения конкретных пороговых требований безопасности. Причем безопасность должна включать в себя не только этические и клинические аспекты, но и информационную безопасность, предполагающую защиту от утечки персональных данных при использовании облачных моделей [17]. Подобные БГМ, подходящие для работы в защищенном контуре, при этом способны стать решением для задачи сбалансированности мощностей и стоимости модели. Настоящее исследование не выявило никаких значимых отличий в результатах работы облачных и локально развернутых БГМ, следовательно, необходимо обратить дополнительное внимание на небольшие модели при проведении дальнейших исследований. Вероятно, качество их работы в рамках подобных задач вполне может не уступать большим БГМ.

Однако для подтверждения этой гипотезы и полноценной реализации пациентского сервиса на основе БГМ необходима разработка многоуровневой системы контроля качества работы моделей.

Уже сейчас по результатам этой работы мы можем сформулировать основные требования к ответу БГМ для расширения промпта. Рекомендуемый формат ответа большой языковой модели:

1. Заявление об ограничении применения (дисclaimer).
2. Название диагностического исследования.
3. Общая интерпретация проведенного исследования (опционально):
 - 3.1 краткое описание выявленных изменений;
 - 3.2 краткое описание органов и структур, информация о которых есть в протоколе врача, изменений в которых не выявлено (например, описание печени, почек соответствует популяционной норме).

4. Трактовка выявленных изменений (согласно протоколу врача).

5. Рекомендации (согласно протоколу врача).

При этом ответ БГМ не должен содержать следующей информации:

1. Предполагаемые по результатам диагностического исследования диагнозы, состояния или прогнозы.
2. Рекомендации об обращении к врачу конкретной специальности, о дополнительных исследованиях и лечении, которых нет в протоколе врача.

БГМ для задачи упрощенной интерпретации медицинских протоколов рекомендуется применять в отношении диагностических исследований, проведенных при оказании плановой медицинской помощи пациентам старше 18 лет, выполненных в амбулаторных условиях и/или при проведении профилактических осмотров населения.

Таким образом, настоящая работа демонстрирует несостоятельность на данный момент проанализированных БГМ (как больших, так и средних) в решении задачи интерпретации медицинских текстов без системы контроля качества их работы, подтверждая их небезопасность. Однако потенциал применения генеративных моделей может быть реализован путем разработки воспроизводимой, научно-обоснованной системы оценивания результатов их работы, первый шаг к которой уже был сделан в настоящем исследовании.

ОГРАНИЧЕНИЯ

Наши выводы ограничены размером тестового набора и числом респондентов; оценки «тревоги/тона» по своей природе субъективны и требуют разработки и валидации отдельных опросников. Также в работу было включено ограниченное количество БГМ, среди которых мы сознательно не включали специализированные модели, обученные и рекомендуемые к работе с медицинскими наборами данных.

ЗАКЛЮЧЕНИЕ

Полученные в нашем исследовании результаты указывают на несостоятельность ряда наиболее распространенных больших генеративных моделей в решении задачи интерпретации медицинских текстов для пациентов. Решением

проблемы может стать специальная подготовка моделей, целенаправленное обучение, разработка и применение процедур контроля качества, тщательная проработка дизайна результатов работы модели, в целом реализация мер по недопущению искажений фактического содержания и тона медицинского документа.

Источники финансирования. Данная статья подготовлена авторским коллективом в рамках научно-практического проекта в сфере медицины (№ ЕГИСУ: 125051305989-8) «Перспективный АРМ врача-рентгенолога на основе генеративного искусственного интеллекта».

ЛИТЕРАТУРА/REFERENCES

- 1 Park J, Oh K, Han K, Lee YH. Patient-centered radiology reports with generative artificial intelligence: adding value to radiology reporting. *Sci Rep.* 2024; 14: 13218. doi: 10.1038/s41598-024-63824-z.
- 2 Starcevic V, Berle D. Cyberchondria: towards a better understanding of excessive health-related Internet use. *Expert Rev Neurother.* 2013; 13: 205-13. doi: 10.1586/ern.12.162.
- 3 Luo A, Qin L, Yuan Y, et al. The Effect of Online Health Information Seeking on Physician-Patient Relationships: Systematic Review. *J Med Internet Res.* 2022; 24: e23354. doi: 10.2196/23354.
- 4 Васильев Ю.А., Решетников Р.В., Нанова О.Г., и др. Применение больших языковых моделей в лучевой диагностике: обзор предметного поля // *Digital Diagnostics.* – 2025. – Т.6. – №2. – С.268-285. [Vasilev YuA, Reshetnikov RV, Nanova OG, et al. Application of Large Language Models in Radiological Diagnostics: A Scoping Review. *Digital Diagnostics.* 2025; 6(2): 268–85. (In Russ.))] doi: 10.17816/DD678373.
- 5 Hager P, Jungmann F, Holland R, et al. Evaluation and mitigation of the limitations of large language models in clinical decision-making. *Nat Med* 2024; 30: 2613-22. doi: 10.1038/s41591-024-03097-1.
- 6 Aydin S, Karabacak M, Vlachos V, Margetis K. Large language models in patient education: a scoping review of applications in medicine. *Front Med* 2024; 11: 1477898. doi: 10.3389/fmed.2024.1477898.
- 7 Cohen J. Statistical power analysis for the behavioral sciences. 2nd ed. Hillsdale, NJ: L. Erlbaum Associates; 1988.
- 8 Hedges LV. A random effects model for effect sizes. *Psychol Bull* 1983; 93: 388-95. doi: 10.1037/0033-2909.93.2.388.
- 9 Doshi R, Amin KS, Khosla P, et al. Quantitative Evaluation of Large Language Models to Streamline Radiology Report Impressions: A Multimodal Retrospective Analysis. *Radiology* 2024; 310: e231593. doi: 10.1148/radiol.231593.
- 10 Rahsepar AA. Large Language Models for Enhancing Radiology Report Impressions: Improve Readability While Decreasing Burnout. *Radiology.* 2024; 310: e240498. doi: 10.1148/radiol.240498.
- 11 Van Der Mee FAM, Ottenheijm RPG, Gentry EGS, et al. The impact of different radiology report formats on patient information processing: a systematic review. *Eur Radiol.* 2024; 35: 2644-57. doi: 10.1007/s00330-024-11165-w.
- 12 Steitz BD, Turer RW, Salmi L, et al. Repeated Access to Patient Portal While Awaiting Test Results and Patient-Initiated Messaging. *JAMA Netw Open.* 2025; 8: e254019. doi: 10.1001/jamanetworkopen.2025.4019.
- 13 Anyidoho PA, Verschraegen CF, Markham MJ, et al. Impact of the Immediate Release of Clinical Information Rules on Health Care Delivery to Patients With Cancer. *JCO Oncol Pract.* 2023; 19: e706-13. doi: 10.1200/OP.22.00712.
- 14 Lee H-S, Kim S, Kim S, et al. Readability versus accuracy in LLM-transformed radiology reports: stakeholder preferences across reading grade levels. *Radiol Med (Torino).* 2025. doi: 10.1007/s11547-025-02098-5.
- 15 Park J, Oh K, Han K, Lee YH. Patient-centered radiology reports with generative artificial intelligence: adding value to radiology reporting. *Sci Rep.* 2024; 14: 13218. doi: 10.1038/s41598-024-63824-z.
- 16 Ethics and Governance of Artificial Intelligence for Health: Large Multi-Modal Models. WHO Guidance. 1st ed. Geneva: World Health Organization; 2024.
- 17 Искусственный интеллект в лучевой диагностике: *Per Aspera Ad Astra* / Под ред. Ю.А. Васильева и А.В. Владзимирского. – М.: Издательские решения; 2025. [Iskusstvennyy intellekt v luchevoy diagnostike: *Per Aspera Ad Astra.* Ed by Vasilev YA, Vladzimirskyy AV. Moscow: Izdatelskie resheniya; 2025. (In Russ.)]