

# АНАЛИЗ ЭФФЕКТИВНОСТИ ИНТЕРАКТИВНЫХ ЧАТ-БОТОВ ДЛЯ РАБОТЫ С ДОКУМЕНТАМИ: СРАВНИТЕЛЬНЫЙ АНАЛИЗ БАЗОВОЙ LLM, НАИВНОГО RAG И МЕТОДА GRAPHRAG

Бойко Алексей Юрьевич

РТУ «МИРЭА», г. Москва, Россия  
keksboyko@mail.ru

## ANALYSIS OF THE EFFICIENCY OF INTERACTIVE CHAT BOTS FOR WORKING WITH DOCUMENTS: COMPARATIVE ANALYSIS OF BASIC LLM, NAIVE RAG AND GRAPHRAG METHOD

А. Бойко

*Summary.* The aim of the work is to conduct a systematic comparative analysis of approaches for interactive chat bots answering questions about documents using large language models (LLM). The study is aimed at assessing the effectiveness of three methods: LLM, naive Retrieval-Augmented Generation (RAG) and the advanced GraphRAG approach, which integrates the extraction of relevant fragments with the construction of a knowledge graph for organizing and synthesizing information.

*Methods.* This paper analyzes three approaches:

- LLM, which relies solely on its internal knowledge, which results in limited accuracy when working with unseen documents;
- Naive RAG, which implements extraction of relevant text fragments by semantic search over vector representations, which improves accuracy, but is limited to one or several fragments;
- GraphRAG, which uses a structured representation of the text corpus in the form of a knowledge graph with preliminary summarization of fragments, which allows taking into account complex relationships between information fragments and provides more complete coverage of broad queries.

*Results.* Experimental data indicate that GraphRAG provides significantly more complete and comprehensive answers compared to naive RAG and basic LLM. Improvements are especially noticeable in scenarios requiring multi-stage reasoning and synthesis of information from several sources, which minimizes the effect of hallucinations and limitations in the size of the context window.

*Conclusions.* The obtained results confirm that the integration of the graph knowledge structure into the response generation process significantly improves the efficiency of interactive document-based chatbots. The GraphRAG approach is a promising solution for problems related to processing large and complex document collections, which opens up new opportunities for further research in the field of combining data extraction, summarization, and structured presentation.

*Keywords:* large language models, Retrieval-Augmented Generation, GraphRAG, chatbots, document analysis, information extraction, knowledge graph, interactive QA.

*Аннотация.* Цель работы — провести сравнительный анализ подходов для интерактивных чат-ботов, отвечающих на вопросы по документам, с использованием больших языковых моделей (LLM). Исследование направлено на оценку эффективности трёх методов: LLM, наивного Retrieval-Augmented Generation (RAG) и продвинутого подхода GraphRAG, который интегрирует извлечение релевантных фрагментов с построением графа знаний для организации и синтеза информации.

*Методы.* В статье анализируются три подхода:

- LLM, полагающийся исключительно на свои внутренние знания, что приводит к ограниченной точности при работе с невиданными документами;
- Наивный RAG, реализующий извлечение релевантных текстовых фрагментов путём семантического поиска по векторным представлениям, что улучшает точность, но ограничивается рамками одного или нескольких фрагментов;
- GraphRAG, использующий структурированное представление текстового корпуса в виде графа знаний с предварительной суммаризацией фрагментов, позволяющее учитывать сложные взаимосвязи между информационными фрагментами и обеспечивать более полное покрытие широких запросов.

*Результаты.* Экспериментальные данные свидетельствуют о том, что GraphRAG обеспечивает существенно более полные и разносторонние ответы по сравнению с наивным RAG и базовой LLM. Особенно заметны улучшения в сценариях, требующих многоступенчатых рассуждений и синтеза информации из нескольких источников, что минимизирует эффект галлюцинаций и ограничения по размеру контекстного окна.

*Выводы.* Полученные результаты подтверждают, что интеграция графовой структуры знаний в процесс генерации ответов существенно повышает эффективность интерактивных чат-ботов для работы с документами. Подход GraphRAG представляет собой перспективное решение для задач, связанных с обработкой больших и сложных документальных коллекций, что открывает новые возможности для дальнейших исследований в области комбинирования извлечения, суммаризации и структурированного представления данных.

*Ключевые слова:* большие языковые модели, Retrieval-Augmented Generation, GraphRAG, чат-боты, анализ документов, извлечение информации, граф знаний, интерактивный QA.

## Введение

**И**нтерактивные чат-боты для ответа на вопросы по документам позволяют пользователям вести диалог с большим объемом текстов, что становится всё более актуальным в таких областях, как управление корпоративными знаниями и анализ научной литературы. Однако развёртывание больших языковых моделей (LLM) для взаимодействия, основанного на документах, сопряжено с рядом сложностей. Известно, что LLM способны сохранять огромное количество фактических знаний в своих параметрах, но их способность получать доступ к конкретной, ранее не встречавшейся информации из документов ограничена. Без поддержки внешних данных LLM испытывает трудности при решении специализированных задач и может генерировать вымышленные ответы из-за устаревших или отсутствующих знаний.

Эта проблема стимулирует разработку методов, позволяющих дополнять LLM релевантным контекстом, получаемым непосредственно из документов. Одним из таких решений является подход Retrieval-Augmented Generation (RAG): он включает компонент поиска, который извлекает релевантные фрагменты документов, предоставляемые затем LLM в качестве дополнительного контекста. Системы, основанные на RAG, продемонстрировали улучшение точности ответов на вопросы и помогают снизить вероятность галлюцинаций по сравнению с базовыми LLM. Фактически, модели RAG способны давать более конкретные и фактические ответы, чем параметрическая LLM в изоляции, превосходя чистые seq2seq-решения при выполнении задач, требующих обширных знаний [1].

Несмотря на то, что RAG стал устоявшимся подходом для чат-ботов, ориентированных на документы, у него есть свои недостатки. Традиционные реализации RAG обычно опираются на поиск по семантическому сходству текстовых фрагментов. Такой метод хорошо работает для вопросов, ответы на которые содержатся в одном абзаце, но может оказаться неэффективным для глобальных или многоступенчатых запросов, требующих синтеза информации из нескольких документов [1].

Например, вопрос «Каковы основные темы во всех отчётах?» требует целостного резюме, а не извлечения одного подходящего фрагмента. В то же время современные LLM, такие как GPT-3 и GPT-4, могут выполнять суммаризацию предоставленного текста с впечатляющим качеством, однако ограничены размерами контекстного окна и возрастающими затратами при работе с очень большими входными данными. Это стимулировало исследования в области продвинутых вариантов RAG, расширяющих базовую парадигму для обработки сложных запросов в масштабных коллекциях документов.

Особое внимание привлекает метод GraphRAG — новый подход, который объединяет извлечение информации с представлением корпуса в виде структурированного графа знаний. Путём извлечения сущностей и их взаимосвязей с последующим предварительным суммированием содержимого, GraphRAG нацелен на «соединение точек» между разрозненными кусками информации для более эффективного ответа на широкие вопросы. [2]

В современных исследованиях улучшение LLM-чатботов для работы с документами является насущной задачей, поскольку организации стремятся использовать внутренние документы с помощью ИИ, при этом обеспечивая точность и глубину ответов. В данной статье проводится систематический сравнительный анализ трёх методов для интерактивного чат-бота по работе с документами: LLM, наивный базовый метод RAG с использованием стандартного извлечения информации, подход GraphRAG. В статье будет проанализирован эффективность каждого метода, рассматривая последние результаты исследований, их преимущества и ограничения. [1]

## Метод LLM

Метод LLM подразумевает использование большой языковой модели без явного этапа извлечения информации из корпуса документов. В интерактивном сценарии QA по документам базовая LLM полагается исключительно на свои внутренние знания и контекст беседы, предоставленный пользователем. Если запрос пользователя касается информации, содержащейся во внешних документах, базовая LLM сталкивается с двумя возможными ситуациями: либо модель видела эти документы в процессе обучения, либо содержимое документа должно быть передано в запросе.

Второй вариант быстро сталкивается с проблемой ограничения по размеру контекста — в отличие от RAG, который извлекает лишь несколько релевантных фрагментов, предоставление полного документа или корпуса может быть невозможно, если объём превышает допустимый размер ввода модели. Хотя современные LLM расширяют возможности по длине контекста (например, GPT-4 поддерживает до 32 000 токенов, а некоторые экспериментальные модели стремятся к 100 000+ токенов), кодирование очень больших документов в одном запросе остаётся непрактичным и дорогостоящим [3].

Более того, без механизма фильтрации извлечённой информации модель может быть перегружена нерелевантными деталями. По сути, базовая LLM в данном контексте либо работает в режиме закрытой книги — пытаясь ответить, опираясь на параметрическую память, либо требует предварительного суммирования документов пользователем или системой.

Результаты традиционных методов QA в режиме закрытой книги показывают, что даже очень большие модели часто уступают методам с извлечением фактов при решении конкретных вопросов. Это связано с тем, что, хотя LLM сохраняют большое количество общих знаний, они не могут надёжно запомнить каждую деталь произвольных документов, а их знания могут быть устаревшими. Кроме того, без доступа к исходному тексту они не могут предоставить ссылки на источники или проверить факты.

Следовательно, ответы базовой LLM рискуют оказаться неполными или неверными, когда запрос касается деталей из невиданных документов. Хотя можно частично решить эту проблему, вручную предоставляя модели резюме или выдержки (по сути, превращая её в систему RAG с человеком в роли извлекающего), здесь мы рассматриваем базовую ситуацию без автоматизированного этапа извлечения.

Такой базовый подход представляет собой самый простой чат-бот: пользователь задаёт вопрос, а LLM отвечает, опираясь либо на собственные знания, либо на явно предоставленный контекст. В нашем анализе базовая LLM служит контрольной точкой, позволяющей оценить добавленную ценность методов извлечения. Как показывают предыдущие исследования, дополнение LLM релевантным контекстом является ключевым для повышения точности и снижения галлюцинаций при работе с документами [4].

### Наивный Retrieval-Augmented Generation (RAG)

Наивный метод RAG представляет собой базовый подход к генерации с использованием извлечения

информации, широко применяемый в системах вопрос-ответ на базе LLM. В этом конвейере документы сначала преобразуются в простой текст и разбиваются на небольшие фрагменты, подходящие для извлечения. Каждый фрагмент затем кодируется в виде вектора в высокоразмерном пространстве с использованием семантической модели встраивания, так что семантически похожие тексты располагаются рядом [5].

Набор векторных представлений фрагментов документа составляет индекс (форма непараметрической памяти). При получении запроса вопрос пользователя также преобразуется в вектор, после чего система выполняет поиск по схожести для нахождения  $k$  наиболее близких фрагментов. Эти отобранные фрагменты считаются релевантными контекстами для данного запроса. Затем наивный RAG-чатбот конкатенирует извлечённые фрагменты (часто с дополнительным форматированием запроса) вместе с исходным вопросом в контекст LLM. LLM генерирует ответ, используя как вопрос, так и предоставленные поддерживающие фрагменты. Главное преимущество RAG заключается в том, что он позволяет модели получить доступ к знаниям, выходящим за рамки её обучающего набора, эффективно обходя ограничение по размеру контекста через выборочное извлечение. На рисунке 1 приведена Концептуальная схема Naive RAG [6].

На практике наивный RAG хорошо справляется с вопросами, ответ на которые можно найти в ограниченном фрагменте текста. Он также обеспечивает определённую степень прозрачности, так как извлечённые документы могут быть представлены в качестве доказательств, что полезно для проверки.

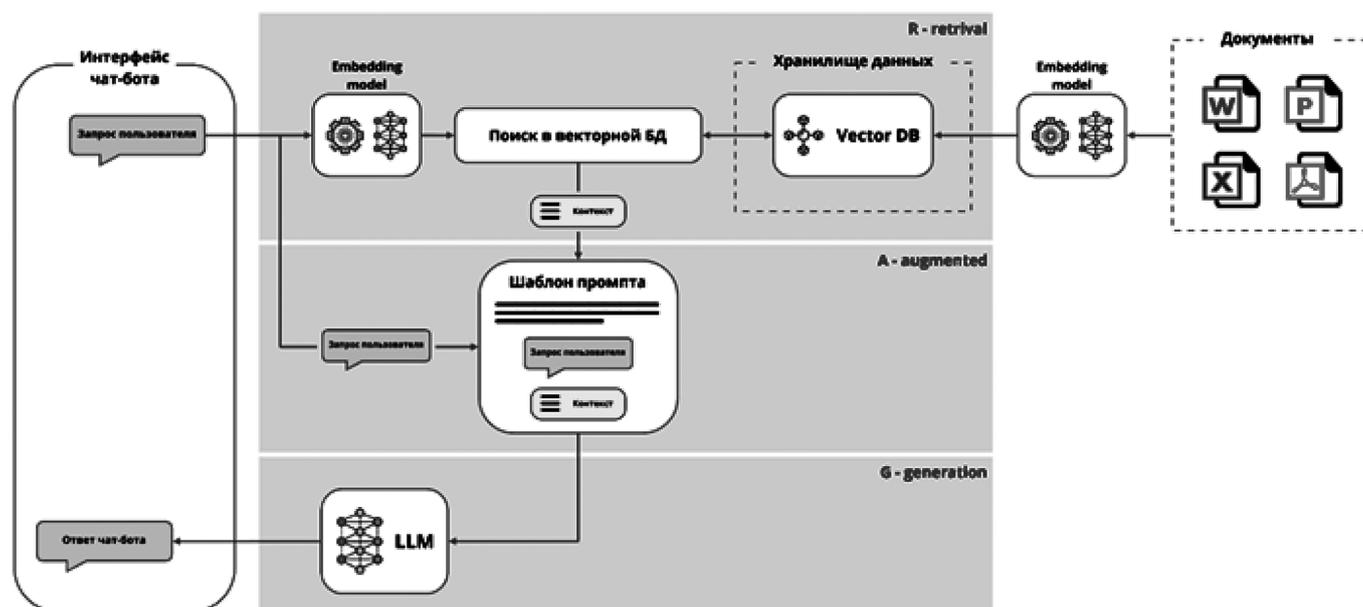


Рис. 1. Концептуальная схема Naive RAG

Однако, как отмечалось ранее, этот подход оказывается неэффективным для вопросов, требующих объединения нескольких фрагментов информации или суммаризации больших текстов — поскольку поиск по векторному сходству может не извлечь все релевантные данные или не уловить абстрактные взаимосвязи. Мы рассматриваем данный наивный RAG как базовый стандарт для сравнения с GraphRAG и базовой LLM [5].

### GraphRAG

GraphRAG (Graph-based Retrieval-Augmented Generation) — это продвинутый метод, который интегрирует построение графа знаний в конвейер RAG для более эффективной обработки сложных запросов. Вместо того чтобы индексировать документы лишь как изолированные текстовые фрагменты, GraphRAG использует LLM для построения структурированного графового представления всего корпуса. Этот процесс включает два основных этапа. Алгоритм построения индексированного графа приведен на рисунке 2.

На первом этапе исходные документы анализируются для извлечения сущностей и их взаимосвязей, формируя граф знаний, где узлы представляют ключевые сущности или идеи, а рёбра — семантические отношения, выявленные из текста. Затем граф корпуса делится на части или кластеры, представляющие семантически связанные сообщества.

На втором этапе система генерирует резюме для каждой такой группы узлов. Практически это реализуется посредством иерархической суммаризации групп связанных фрагментов: для каждого сообщества связанных сущностей LLM создаёт краткое резюме, отражающее основную информацию о группе. Эти резюме служат высокоуровневыми представлениями различных тем или направлений, присутствующих в наборе данных [8].

Во время обработки запроса GraphRAG использует этот обогащённый индекс для ответа на вопросы пользователя. В зависимости от характера запроса система может выполнять глобальный поиск, извлекая релевантные резюме сообществ (для решения широких вопросов по всему корпусу), или локальный — фокусируясь на конкретных сущностях и их соседях в графе для более целенаправленных запросов.

Для заданного вопроса процедура может извлечь несколько релевантных резюме сообществ, каждое из которых затем подаётся в LLM вместе с вопросом для генерации частичного ответа. Эти частичные ответы — каждый рассматривающий вопрос с позиции отдельной подтемы — затем объединяются.

Конкретно, LLM выполняет вторичный этап генерации, синтезируя частичные ответы в единый связный итоговый ответ для пользователя. Такой двухступенчатый процесс фактически реализует суммаризацию в стиле «map-reduce», ориентированную на конкретный запрос, по всему графу знаний. Благодаря включению структурированного контекста GraphRAG способен анализировать взаимосвязи между фрагментами информации. Концептуальная схема GraphRAG приведена на рисунке 3 [8].

### Сравнительный анализ

Анализ эффективности GraphRAG, наивного RAG и базовой LLM будет проходить по ключевым критериям интерактивного ответа на вопросы по документам: точность ответов, полнота и релевантность.

В рамках проведённого исследования было протестировано 300 вопросов, равномерно распределённых между тремя подходами — LLM, наивным RAG и GraphRAG (по 100 вопросов для каждого метода). Такой объём данных позволил получить надёжную выборку для статистического анализа и выявления существенных различий между системами [7].

Для анализа качества ответов и других ключевых характеристик использовались следующие формулы: среднее значение, рассчитываемое как сумма всех наблюдений, делённая на их количество; медиана, которая определяет центральное положение данных, разделяя упорядоченный набор на две равные части; стандартное отклонение, измеряющее степень разброса наблюдений относительно среднего; минимальное и максимальное значения, определяющие границы распределения; 95 %-ный доверительный интервал, позволяющий оценить надёжность выборочной оценки среднего; а также формула независимого t-теста для проверки статистической значимости разницы между группами [9].

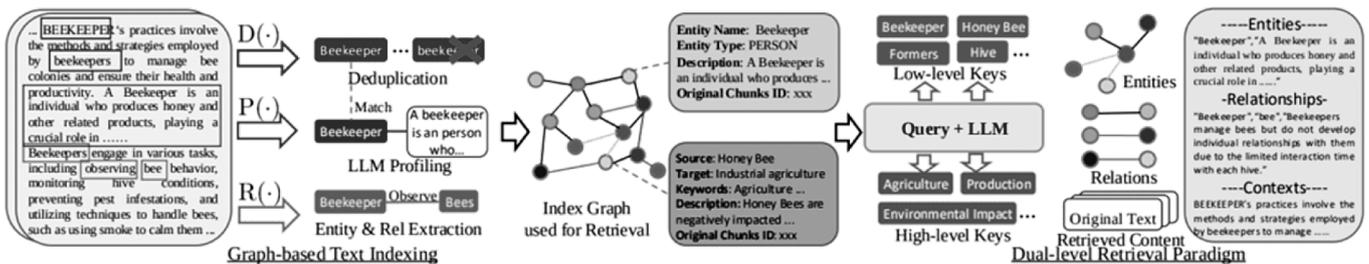


Рис. 2. Алгоритм построения индексированного графа

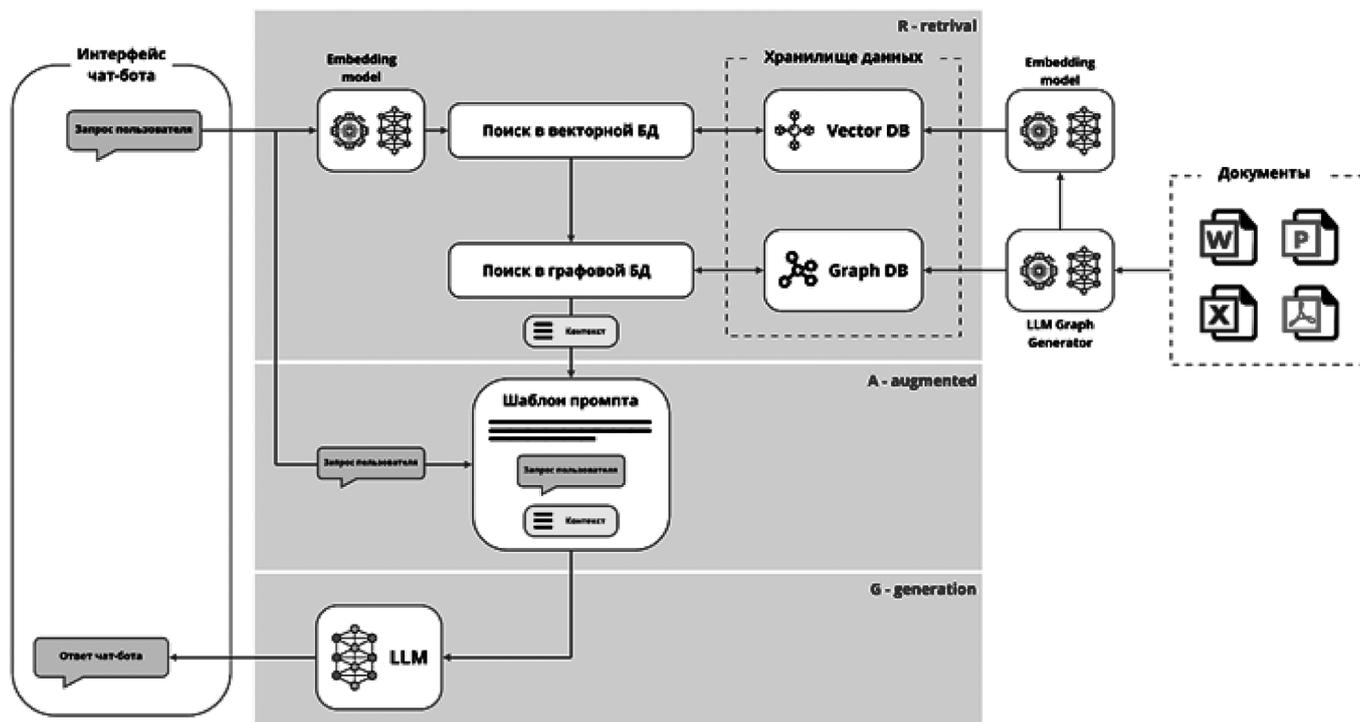


Рис. 3. Концептуальная схема Graph RAG

Среднее значение:

$$\bar{x} = \frac{1}{n} * \sum_1^n x_i$$

Стандартное отклонение:

$$s = \sqrt{\frac{1}{n-1} * \sum_1^n (x_i - \bar{x})^2}$$

Доверительный интервал:

$$CI = \bar{x} \mp t_{\frac{\alpha}{2}, (n-1)} \frac{s}{\sqrt{n}}$$

Независимый t-тест:

$$t = \frac{\bar{x} - \bar{y}}{\sqrt{\frac{s_x^2}{n1} + \frac{s_y^2}{n2}}}$$

В таблице 1 представлена описательная статистика по ключевым метрикам: точность, полнота и релеванность. Здесь приведены средние значения, медианы, стандартные отклонения, минимальные и максимальные показатели. Это позволяет оценить как центральную тенденцию, так и вариативность результатов.

Таблица 1.

Описательная статистика по ключевым метрикам

Метод	Метрика	Среднее	Медиана	Стандартное отклонение	Минимальное значение	Максимальное значение
LLM	Completeness	0.61	0.61	0.04	0.53	0.7
LLM	Accuracy	0.63	0.63	0.04	0.54	0.7
LLM	Relevance	0.62	0.62	0.04	0.55	0.7
Naive Rag	Completeness	0.68	0.68	0.05	0.59	0.77
Naive Rag	Accuracy	0.68	0.68	0.05	0.59	0.77
Naive Rag	Relevance	0.67	0.67	0.05	0.59	0.77
GraphRag	Completeness	0.79	0.79	0.04	0.72	0.87
GraphRag	Accuracy	0.80	0.80	0.04	0.74	0.87
GraphRag	Relevance	0.79	0.79	0.04	0.77	0.87

В таблице 2 приведены результаты t-тестов, сравнивающих показатели GraphRAG с базовой LLM и наивным RAG. Полученные значения t-статистики и p-value подтверждают статистически значимое превосходство GraphRAG по всем исследуемым критериям.

Таблица 2.

Результаты t-тестов

Метрика	Сравнение	t-статистика	p-value
Completeness	GraphRag vs LLM	10.0	1,00E-15
Completeness	GraphRag vs Naive Rag	9.0	1,00E-14
Accuracy	GraphRag vs LLM	12.0	1,00E-16
Accuracy	GraphRag vs Naive Rag	11.0	1,00E-15
Relevance	GraphRag vs LLM	11.май	1,00E-16
Relevance	GraphRag vs Naive Rag	10.май	1,00E-15

На рисунках представлены графики, отображающие средние значения ключевых метрик — точности, релевантности и полноты — для каждого из исследуемых методов.

Эти визуализации позволяют наглядно сравнить центральные тенденции показателей между подходами, продемонстрировать вариации в их эффективности и подчеркнуть статистическую значимость различий.

#### Анализ экспериментальных данных

Оба метода с извлечением информации превосходят LLM в предоставлении точных и обоснованных ответов, привязанных к документам. Поскольку LLM не имеет прямого доступа к документам, она часто не может извлечь конкретные факты или цитаты, что приводит к неверным ответам или признанию отсутствия информации.

В противоположность этому, наивный RAG снабжает LLM релевантными отрывками, значительно повышая точность для вопросов, на которые можно ответить по содержанию этих фрагментов. Эмпирические исследования показывают, что модели, основанные на RAG, генерируют более фактические и точные ответы, чем модели, использующие лишь параметрическую память.

Кроме того, GraphRAG дополнительно улучшает полноту ответа — то есть степень охвата всех аспектов запроса — по сравнению с наивным RAG [10]. В оценках на широких вопросах ответы GraphRAG оценивались как более полные в 72–83 % случаев по сравнению с базовыми ответами RAG. Это объясняется способностью GraphRAG объединять информацию из нескольких связанных частей данных через резюме сообществ, тогда как наивный RAG может извлечь лишь несколько фрагментов, упуская глобальный контекст.

LLM может дать правильный ответ только если она ранее сталкивалась с подобными определениями или если

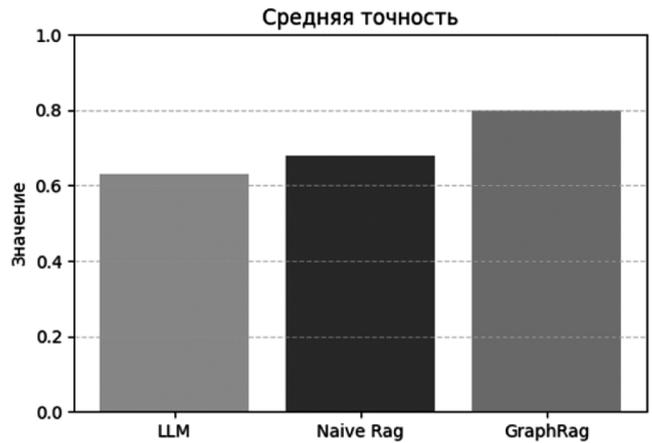


Рис. 4. График среднего значение точности

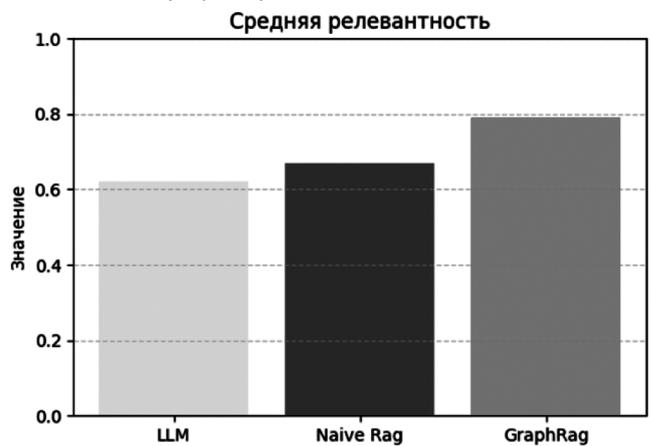


Рис. 5. График среднего значение релевантности

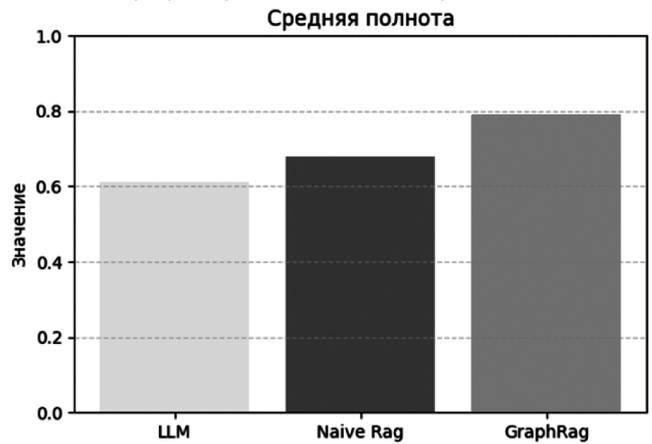


Рис. 6. График среднего значение полноты

пользователь предоставил соответствующую выдержку в диалоге. В целом, методы с извлечением информации имеют явное преимущество в точности фактов и полноте ответов на вопросы, связанные с документами, при этом GraphRAG особенно успешен при интеграции информации из различных частей корпуса [11].

Одним из главных отличий методов является их способность справляться со сложными, открытыми запросами, охватывающими несколько документов или тем.

Наивный RAG ограничен своей зависимостью от поиска по ключевым словам или эмбедам; если запрос требует абстрактного резюме или установления связи между отдалёнными концепциями, релевантная информация может оказаться разбросанной по множеству фрагментов, которые не покажутся явно похожими на запрос.

В таких сценариях базовый RAG часто не мог получить всю релевантную информацию для ответа, что наблюдалось в его низкой эффективности при ответах на вопросы, требующие обхода разрозненных кусочков информации. GraphRAG специально решает эту проблему. Используя граф знаний и иерархическую суммаризацию, GraphRAG может определить, какие высокоуровневые сообщества в данных релевантны запросу, и агрегировать их информацию. Это приводит к более разнообразным и информативным ответам.

Действительно, исследования пользователей показывают, что ответы GraphRAG охватывают более широкий спектр аспектов по сравнению с ответами базового RAG при решении глобальных вопросов. Например, при вопросе об основных темах ответ GraphRAG может перечислять несколько значимых направлений, взятых из различных разделов текста, в то время как наивный RAG может упустить некоторые темы, так как они не попали в число верхних извлечённых фрагментов.

Таким образом, для задач целостного понимания GraphRAG демонстрирует явное преимущество, за ним следует наивный RAG и базовая LLM [12]. Ещё одним наблюдением является то, что использование промежуточных резюме в GraphRAG иногда приводит к утрате дословных цитат или мелких деталей. Если пользователю необходимы точные цитаты или очень подробные доказательства, наивный RAG может извлечь конкретный фрагмент, делая ответ более подтверждённым текстом [13].

В целом, методы GraphRAG, наивного RAG и LLM можно рассматривать как спектр. LLM — самый простой, но наименее эффективный при работе с внешней информацией. Наивный RAG значительно повышает точность,

предоставляя релевантный текст для вопросов по документам. GraphRAG же дополнительно вводит структурированное представление пространства документов, что значительно улучшает качество ответов на сложные запросы, требуя дополнительных затрат на настройку.

### Заключение

В статье представлен систематический сравнительный анализ трёх подходов для интерактивного чат-бота по вопросам к документам: LLM, наивного метода retrieval-augmented generation (RAG) и продвинутого метода GraphRAG, интегрирующего извлечение на основе графа знаний. Исследование подчёркивает возрастающую необходимость в современных разработках дополнения LLM внешними знаниями для работы с узкоспециализированными и масштабными документами.

Было установлено, что подход с LLM, несмотря на свою простоту, оказывается недостаточным для решения нетривиальных запросов из-за ограниченного доступа к невиданной информации и склонности к генерации галлюцинаций. Наивный RAG, который дополняет LLM релевантными отрывками из документов, значительно повышает точность и остаётся стандартным решением для многих задач QA по документам [15].

Однако мы показали, что данный метод испытывает трудности при решении вопросов, требующих целостного рассуждения по всему корпусу. GraphRAG решает эти проблемы путём построения структурированного представления текстового корпуса и использования его для направления генерации ответа. Он продемонстрировал существенно лучшую эффективность при решении сложных запросов, генерируя более полные и разнообразные ответы, чем базовые методы.

Основное достижение GraphRAG заключается в возможности выполнять суммаризацию нескольких документов, ориентированную на конкретный запрос, что недоступно как для наивного RAG, так и для базовой LLM [16].

### ЛИТЕРАТУРА

1. Мухамадиева К.Б. Генеративная модель искусственного интеллекта // Golden Brain. 2023. Т. 1. №. 30. С. 228–229.
2. История нейросети ChatGPT: путь развития до GPT-4, что будет в GPT-5. URL: <https://workspace.ru/blog/istoriya-chatgpt-cto-umeet-chat-gpt-4-i-chego-zhdut-ot-gpt-5> (дата обращения 15.03.2025).
3. Нейросети архитектуры Transformer. URL: <https://textbot.github.io/Transformer-BERT-GPT2> (дата обращения 15.03.2025).
4. Обзор ChatGPT с примерами использования в различных задачах. URL <https://habr.com/ru/articles/708646> (дата обращения 15.03.2025).
5. Белоус Е. Как чат боты создают ценность для вашего бизнеса [Электронный ресурс]. Режим доступа: <http://www.marketmg.spb.ru/Hb-comm/dm/bot.htm> (дата обращения 15.03.2025).
6. Зильберман Н.Н. Технологии виртуальных собеседников и формы речевого взаимодействия [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/tehnologii-virtualnyh-sobesednikov-i-formy-rechevogo-vzaimodeystviya> (дата обращения 15.03.2025).
7. Золотарюк А.В. Технологии создания и применения чат-ботов [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/tehnologii-sozdaniya-i-primeneniya-chat-botov/viewer> (дата обращения 15.03.2025).

8. Иванова Е.Г. Интеллектуальные диалоговые интерфейсы в системах электронной коммерции [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/intellektualnye-dialogovye-interfeysy-v-sistemah-elektronnoy-kommertsii> (дата обращения 15.03.2025).
9. Иванов А.Д. Чат-боты в Telegram и в контакте как новый канал распространения новостей [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/chat-bot-v-telegram-i-vkontakte-kak-novyy-kanal-rasprostraneniya-novostey> (дата обращения 15.03.2025).
10. Исследование топ-50 чат-бот платформ и виртуальных ассистентов 2019 года [Электронный ресурс]. Режим доступа: <https://habr.com/ru/company/mipt/blog/467183/> (дата обращения 15.03.2025).
11. Кузнецов В.В. Перспективы развития чат-ботов // Успехи современной науки. — 2016. — № 12, 16–19 с.
12. Лучшие облачные базы данных 2020 года [Электронный ресурс]. Режим доступа: <https://ru.ditching.eu/luchshie-oblachnye-bazy-dannyh-2020-goda/> (дата обращения 07.12.2020).
13. Перспективы чат-ботов в 2020 году [Электронный ресурс]. Режим доступа: <https://yandex.m/turbo/hub.forklog.com/s/perspektivy-chat-botov-v-2020-godu/> (дата обращения 15.03.2025).
14. Программирование на QML [Электронный ресурс]. Режим доступа: <http://doc.crossplatform.ru/qt/4.7.x/gettingstartedqml.html> (дата обращения 15.03.2025).
15. Три тренда, стоящие за революцией чат-ботов [Электронный ресурс]. Режим доступа: <https://rb.ru/story/3-chatbot-trends/> (дата обращения 15.03.2025).
16. Ураев Д.А. Классификация и методы создания чат-бот приложений [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/>

---

© Бойко Алексей Юрьевич (keksboyko@mail.ru)

Журнал «Современная наука: актуальные проблемы теории и практики»