

## ИСПОЛЬЗОВАНИЕ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ В СИСТЕМНОМ АНАЛИЗЕ: МЕТОДЫ ВЕРИФИКАЦИИ И СНИЖЕНИЯ ПРОЕКТНЫХ РИСКОВ

*Григоренко Б.С., Кохнюк К.А. студенты*

*Белорусский государственный университет информатики и радиоэлектроники  
г. Минск, Республика Беларусь*

*Никульшин Б. В. – канд. тех. наук, доцент*

В работе рассматривается применение больших языковых моделей в задачах системного анализа. Анализируются возможности их использования при обработке требований, подготовке проектной документации и формировании диаграмм, а также ограничения, возникающие при отсутствии процедур проверки. Предлагается гибридный подход, основанный на поэтапной декомпозиции требований, предварительной верификации и генерации артефактов под контролем аналитика. Отдельно рассматривается сравнение универсальных и специализированных моделей, обученных на материалах по системному анализу.

Развитие генеративного искусственного интеллекта заметно влияет на деятельность системного аналитика. Современные LLM могут выделять сущности из текстов требований, подготавливать черновики спецификаций, формировать сценарии использования и генерировать текстовую основу для диаграмм. Универсальные системы, к которым относится, например и Gemini, ориентированы на широкий круг задач: работу с документами, помощь в разработке и переход от требований к прототипу, то есть они полезны как общий интеллектуальный помощник.

Однако ускорение работы не означает автоматического повышения её качества. В системной инженерии ключевыми остаются полнота, непротиворечивость и трассируемость требований. Ошибки, допущенные на стадии анализа, затем переходят в проектную документацию, код, тестовые сценарии и бизнес-процессы. Поэтому применение LLM в системном анализе должно рассматриваться не как замена аналитика, а как средство поддержки принятия решений и подготовки промежуточных артефактов [1].

Основная проблема состоит в том, что универсальная языковая модель формирует ответ на основе вероятностного продолжения текста и не обладает инженерным пониманием предметной области.

В результате при прямой генерации спецификаций и диаграмм могут возникать логические разрывы, потеря нефункциональных ограничений, неполный учёт исключительных сценариев и эффект «чёрного ящика», когда формально убедительный ответ воспринимается как корректный без достаточной проверки [2]. Для системного анализа это особенно опасно, так как ошибка в интерпретации требования на раннем этапе масштабируется на весь проект.

Для снижения этих рисков предлагается гибридный подход. На первом этапе модель выполняет декомпозицию требований: выделяет акторов, сущности, события, правила, ограничения и исключения. На втором этапе проводится логическая проверка: для каждого действия уточняются предусловия, постусловия, альтернативные ветви и исключительные ситуации. На третьем этапе на основе уже проверенного набора фактов формируются проектные артефакты. На четвёртом этапе аналитик выполняет экспертную валидацию результата. Такой контур позволяет использовать преимущества LLM, но сохранять инженерный контроль над качеством.

Отдельного внимания заслуживает сравнение универсальной модели и специализированной системы, самостоятельно обученной или дообученной именно под задачи системного анализа. Gemini является мощным универсальным инструментом, но его сильная сторона – широта применения, а не узкая специализация. Напротив, модель, обученная на корпусе требований, спецификаций, use case, BPMN/UML-описаний, проектных шаблонов и примеров верификации, обычно лучше решает профильные аналитические задачи. Это связано с тем, что она точнее распознаёт профессиональную терминологию, устойчивее выделяет обязательные и альтернативные ветви процесса, лучше сохраняет нефункциональные ограничения и чаще формирует ответы в формате, пригодном для непосредственного включения в проектную документацию.

Материалы Google Cloud прямо указывают, что domain-specific fine-tuning адаптирует модель к конкретной области и может повышать точность и релевантность ответов, а также снижать вероятность галлюцинаций; исследования по domain-specific RAG и постобучению также показывают улучшение качества на внутриотраслевых задачах.

Существенным преимуществом специализированной модели является более высокая объяснимость результата в пределах предметной области. Если универсальная модель чаще формирует ответ как связный, но обобщённый текст, то модель, обученная на требованиях, сценариях использования и проектных шаблонах, способна выдавать структуру, ближе к профессиональной логике аналитика: отдельно фиксировать роли, ограничения, исключения и зависимости между

действиями. Это особенно важно в задачах, где требуется не только получить черновой артефакт, но и обосновать, каким образом каждый его элемент связан с исходным требованием.

Практическое преимущество самостоятельно обученной модели также проявляется в возможности её адаптации к внутренним стандартам конкретной организации. В отличие от универсального ИИ, специализированная система может быть настроена на использование корпоративной терминологии, шаблонов спецификаций, правил описания бизнес-процессов и требований к оформлению проектной документации. Благодаря этому снижается объём последующей ручной доработки, а результаты генерации становятся более единообразными и пригодными для включения в рабочий контур анализа и проектирования [3].

Преимущество специализированной модели объясняется несколькими факторами. Во-первых, она обучается на данных, отражающих именно логику системного анализа, а не на широком массиве разнородных текстов. Во-вторых, такая модель лучше усваивает типовые структуры артефактов: описание ролей, предусловий, постусловий, бизнес-правил, исключений и связей между требованиями. В-третьих, её можно дополнительно настраивать под внутренние стандарты организации: шаблоны спецификаций, корпоративные правила именования, требования к безопасности и форматы диаграмм. В результате она даёт не просто связный текст, а более дисциплинированный и воспроизводимый результат.

**Важным условием эффективного применения специализированной модели является качество обучающего корпуса.** Если в обучающую выборку включены формализованные требования, корректные спецификации, примеры диаграмм и верифицированные проектные артефакты, модель лучше воспроизводит профессиональную логику системного анализа. При этом наличие ошибок, противоречий или неполных описаний в данных обучения может привести к тиражированию тех же недостатков в новых результатах. Следовательно, эффективность такой модели зависит не только от архитектуры, но и от качества инженерной подготовки данных [4].

При этом утверждать, что специализированная модель всегда лучше универсальной, было бы некорректно. Её преимущества проявляются прежде всего в узком классе задач, где есть качественный обучающий корпус, понятные критерии оценки и стабильная предметная область. Универсальные модели остаются полезнее в ситуациях, где требуется широкий кругозор, работа с разнородной информацией, быстрый черновой анализ или междисциплинарный поиск решений. Поэтому на практике наиболее эффективным является не противопоставление этих систем, а их осмысленное сочетание.

Для оценки качества такого подхода могут использоваться три основные группы показателей: логическая полнота, согласованность и трассируемость. Первая отражает степень учёта обязательных, альтернативных и исключительных ветвей процесса. Вторая показывает отсутствие противоречий и логических разрывов. Третья характеризует возможность связать каждый элемент диаграммы или спецификации с исходным требованием. Если сравнивать универсальную модель и специализированную, то именно по этим метрикам профильно обученная система должна демонстрировать преимущество в задачах системного анализа.

При этом эффективность специализированной модели должна подтверждаться не только качественными наблюдениями, но и измеримыми показателями. Для такого сравнения целесообразно использовать экспертную оценку полноты учёта требований, количества пропущенных исключительных сценариев, степени сохранения нефункциональных ограничений и уровня трассируемости между исходным текстом и конечным артефактом.

Таким образом, использование LLM в системном анализе целесообразно рассматривать как инструмент инженерного усиления, а не как замену системного аналитика. Наиболее продуктивным является гибридный подход, при котором человек определяет рамки анализа, задаёт критерии корректности и валидирует результат, а ИИ выполняет декомпозицию требований, поиск пропусков и подготовку черновых артефактов. При этом специализированная модель, обученная на материалах системного анализа, может быть эффективнее универсального ИИ Gemini именно в профильных задачах, поскольку лучше учитывает предметную терминологию, ограничения и структуру проектных документов.

Это делает её более пригодной для повышения трассируемости требований и снижения вероятности логических ошибок на ранних этапах проектирования. Кроме того, применение таких моделей способствует стандартизации подготовки аналитических артефактов и повышает воспроизводимость результатов при повторной обработке схожих требований. Это особенно важно в условиях роста сложности информационных систем и увеличения требований к качеству проектной документации.

**Список использованных источников:**

1. Wei, J., Wang, X., Schuurmans, D. et al. *Chain-of-Thought Prompting Elicits Reasoning in Large Language Models*, 2022.
2. NIST. *Artificial Intelligence Risk Management Framework (AI RMF 1.0)*. NIST AI 100-1. 2023.
3. NIST. *Generative Artificial Intelligence Profile*. NIST AI 600-1. 2024.
4. SEBoK. *System Requirements Definition; Requirements Management*. *The Guide to the Systems Engineering Body of Knowledge*.