

## ИНТЕЛЛЕКТУАЛЬНАЯ ГЕНЕРАЦИЯ ГИПОТЕЗ ДЛЯ ПРОДУКТОВЫХ ИССЛЕДОВАНИЙ НА ОСНОВЕ НАУЧНЫХ ПУБЛИКАЦИЙ

Сабанцева А.А., Богодист В.Я., Игитов М.Д.  
Научный руководитель: доцент Горгадзе А.А.  
Университет ИТМО  
vsevolod.bogodist@gmail.com

Работа выполнена в рамках темы НИР №625111 «Алгоритмическая прозрачность и предиктивные модели развития AI-технологий: от базы знаний к навигатору решений».

### Введение

Введение. В продуктовой разработке гипотеза выступает формальной связкой между предполагаемым изменением, механизмом воздействия и измеримым эффектом на метрики. На практике гипотезы часто формулируются эвристически и слабо операционализируются: не фиксируются сегменты, условия применимости, критерии успеха и дизайн проверки. Одновременно существует разрыв между результатами научных исследований (НСИ, поведенческая экономика, маркетинг, методология онлайн-экспериментов) и их переносом в проверяемые продуктовые формулировки. Большие языковые модели способны генерировать идеи, однако без привязки к первоисточникам повышаются риски недостоверных утверждений. Следовательно, требуется метод, который автоматизирует генерацию гипотез и одновременно обеспечивает проверяемое обоснование и воспроизводимость плана тестирования.

Основная часть. Предлагается подход к генерации продуктовых гипотез на основе Retrieval-Augmented Generation (RAG), в котором допустимые утверждения ограничиваются извлеченным контекстом из корпуса научных публикаций. Целевой артефакт системы — набор альтернативных гипотез, каждая из которых содержит: (1) формулировку «Если-то» с указанием сегмента и ожидаемого эффекта; (2) обоснование, согласованное с фрагментами первоисточников; (3) план проверки (тип эксперимента, длительность, целевая и защитные метрики, критерии останова); (4) ссылки на публикации.

Архитектура включает три слоя. Слой извлечения реализует семантический поиск по векторным представлениям текстов публикаций с ограничениями top-k и порогами сходства; при необходимости применяется reranking для повышения точности выдачи. Слой генерации преобразует извлеченные фрагменты в гипотезы и протокол эксперимента в стандартизированном формате. Слой контроля качества проверяет: (а) наличие всех обязательных полей; (б) соответствие обоснования извлеченному контексту; (в) отсутствие причинно-следственных заявлений вне источников. Дополнительно рассчитывается показатель уверенности как функция релевантности извлечения и согласованности текста с контекстом. Для научной оценки качества решения предлагается двухуровневая схема: (1) метрики извлечения (precision@k, nDCG) на размеченных запросах; (2) метрики генерации — структурная корректность, пригодность гипотез к тестированию и «верность» ответов контексту. Таким образом, система формализует переход «публикация → проверяемая продуктовая гипотеза» и снижает трудозатраты на подготовку исследования при сохранении проверяемости и прозрачности.

Выводы. RAG-подход позволяет получать воспроизводимые продуктовые гипотезы, снабженные источниками и готовым планом проверки, что повышает качество операционализации и снижает зависимость от интуитивных решений. Практическое

использование включает ускорение подготовки backlog гипотез, унификацию протоколов А/В-тестов и накопление корпоративной базы знаний (гипотеза-обоснование-результат). Перспективы внедрения: расширение корпуса публикаций, интеграция с трекером экспериментов и усиление автоматизированного контроля качества генерации.

#### **Список использованных источников**

1. Lewis P., Perez E., Piktus A. et al. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks // NeurIPS. 2020. [Электронный ресурс]. Режим доступа: <https://proceedings.neurips.cc/paper/2020/hash/6b493230205f780e1bc26945df7481e5-Abstract.html> (дата обращения: 28.02.2026).
2. Karpukhin V., Oguz B., Min S. et al. Dense Passage Retrieval for Open-Domain Question Answering // EMNLP. 2020. P. 6769–6781. DOI: 10.18653/v1/2020.emnlp-main.550. [Электронный ресурс]. Режим доступа: <https://aclanthology.org/2020.emnlp-main.550/> (дата обращения: 28.02.2026).
3. Es S., James J., Espinosa-Anke L., Schockaert S. RAGAs: Automated Evaluation of Retrieval Augmented Generation // EACL (System Demonstrations). 2024. P. 150–158. DOI: 10.18653/v1/2024.eacl-demo.16. [Электронный ресурс]. Режим доступа: <https://aclanthology.org/2024.eacl-demo.16/> (дата обращения: 28.02.2026).
4. Kohavi R., Longbotham R., Sommerfield D., Henne R. M. Controlled experiments on the web: survey and practical guide // Data Mining and Knowledge Discovery. 2009. Vol. 18, No. 1. P. 140–181. DOI: 10.1007/s10618-008-0114-1. [Электронный ресурс]. Режим доступа: <https://link.springer.com/article/10.1007/s10618-008-0114-1> (дата обращения: 28.02.2026).
5. Kohavi R., Tang D., Xu Y. Trustworthy Online Controlled Experiments: A Practical Guide to A/B Testing. Cambridge: Cambridge University Press, 2020. [Электронный ресурс]. Режим доступа: <https://www.cambridge.org/core/books/trustworthy-online-controlled-experiments/D97B26382EB0EB2DC2019A7A7B518F59> (дата обращения: 28.02.2026).
6. Huang L. et al. A Survey on Hallucination in Large Language Models // ACM Computing Surveys. 2025. DOI: 10.1145/3703155. [Электронный ресурс]. Режим доступа: <https://dl.acm.org/doi/abs/10.1145/3703155> (дата обращения: 28.02.2026).