

# Вопрос-ответные системы в облаке Yandex Cloud на основе продвинутого RAG и многоагентности

**Дмитрий Сошников**

Доцент НИУ ВШЭ/МАИ,  
консультант Yandex Cloud,  
тех. руководитель AI Lab ШД НИУ ВШЭ

Tg: @shwarsico

**Яндекс**



**ХАЛЯВА**

# Типовая задача

Специализированный чат-бот,  
который обладает предметными знаниями



# Типовая задача

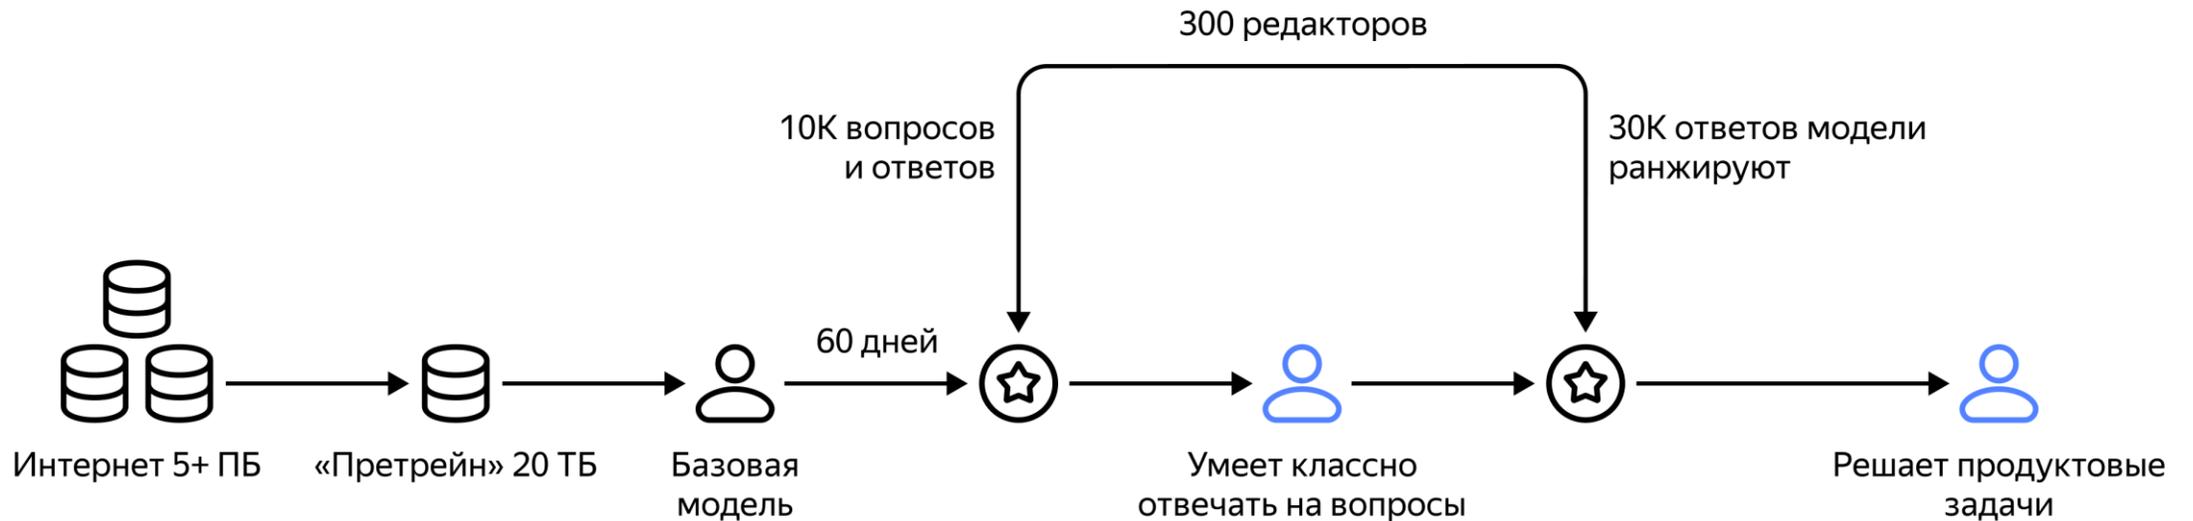
Специализированный чат-бот,  
который обладает предметными знаниями



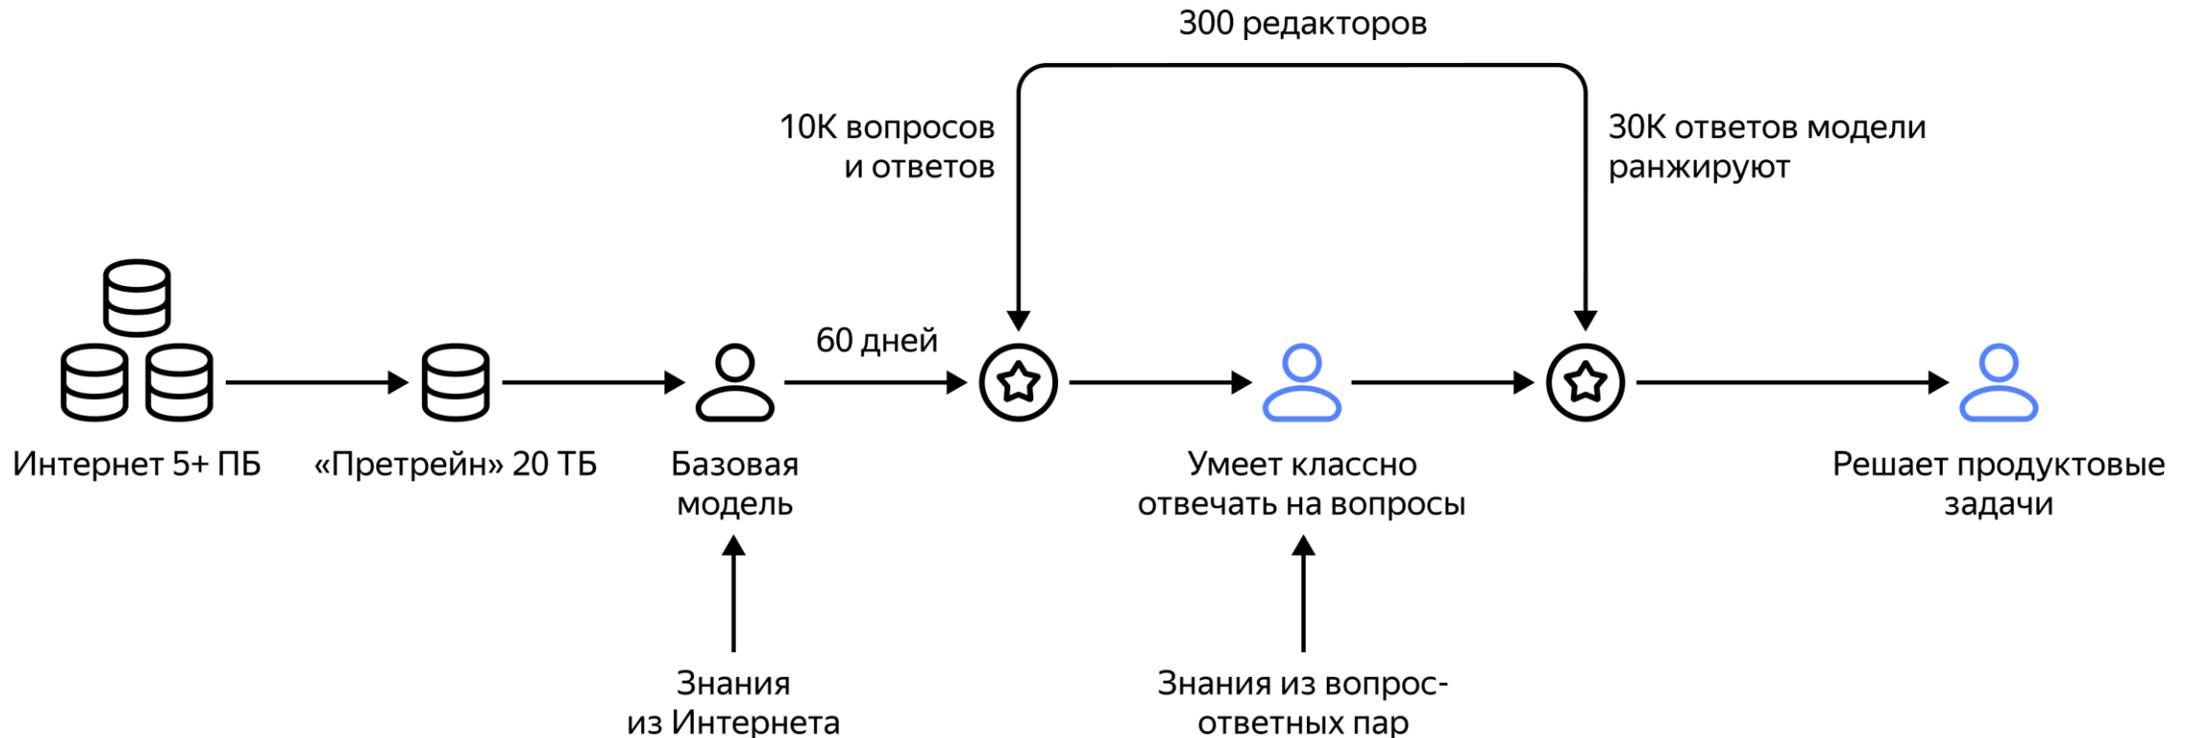
Употребление алкоголя вредит вашему здоровью...



# Откуда берутся знания у LLM



# Откуда берутся знания у LLM



# Как добавить знания в LLM?

## Дообучение модели



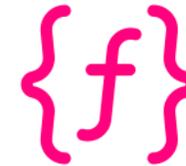
### Full Fine-Tuning

- Много обучающих примеров
- Много ресурсов на обучение
- Изменяются веса исходной модели
- Получается новая языковая модель с большим числом параметров



### LoRA Fine-Tuning

- Вместо обучения всех параметров обучается «добавка» к весам, которая раскладывается на матрицы меньшей размерности
- Из-за меньшего количества параметров нужно меньше данных и меньше вычислительных ресурсов



### P-Tuning

- Параметры модели не меняются, но подбирается continuous prompt embedding, который помогает достичь нужных результатов
- Требуется меньше всего вычислительных ресурсов и данных для обучения
- Хорошо работает на изменение формата ответа, но не знаний модели



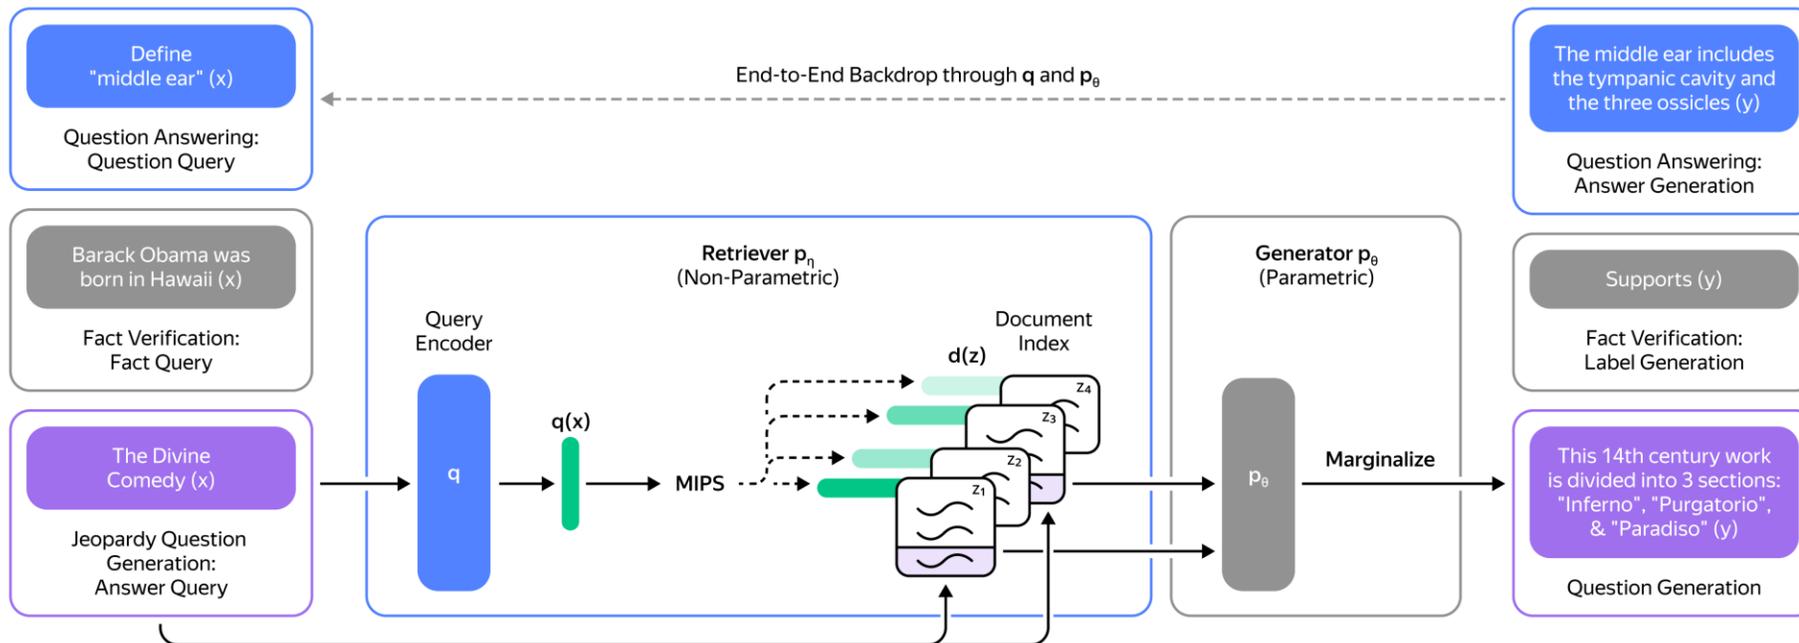
# Как добавить знания в LLM: RAG

## Retrieval-Augmented Generation

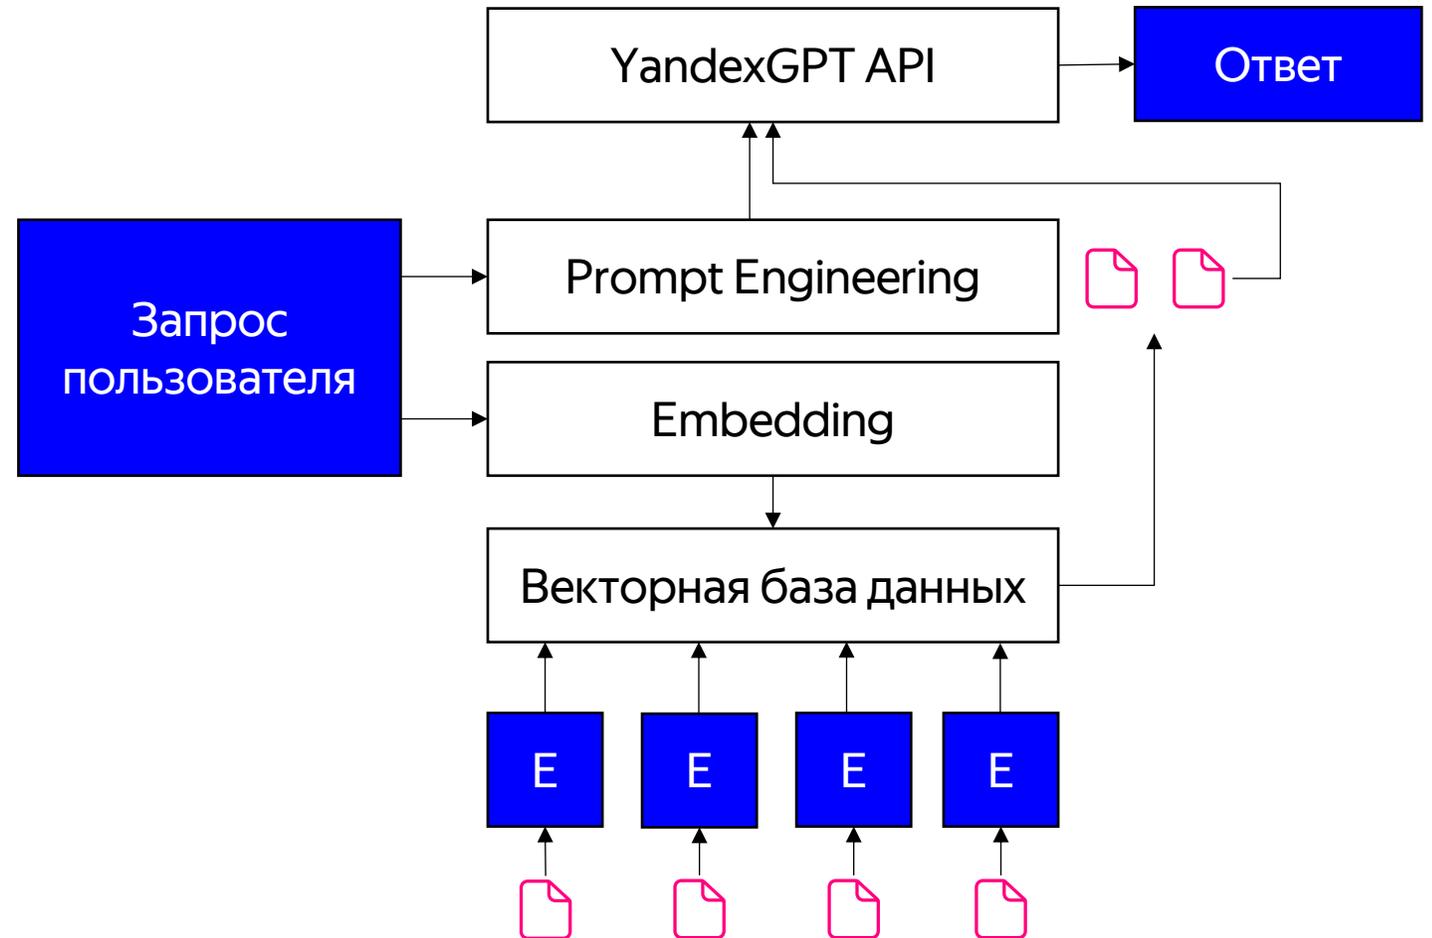
Lewis, Patrick, et al. «Retrieval-augmented generation for knowledge-intensive nlp tasks.» Advances in Neural Information Processing Systems 33 (2020): 9459-9474.

**RAG-Sequence:** для генерации всей последовательности используются одни и те же документы

**RAG-Token:** для генерации каждого токена могут использоваться разные документы



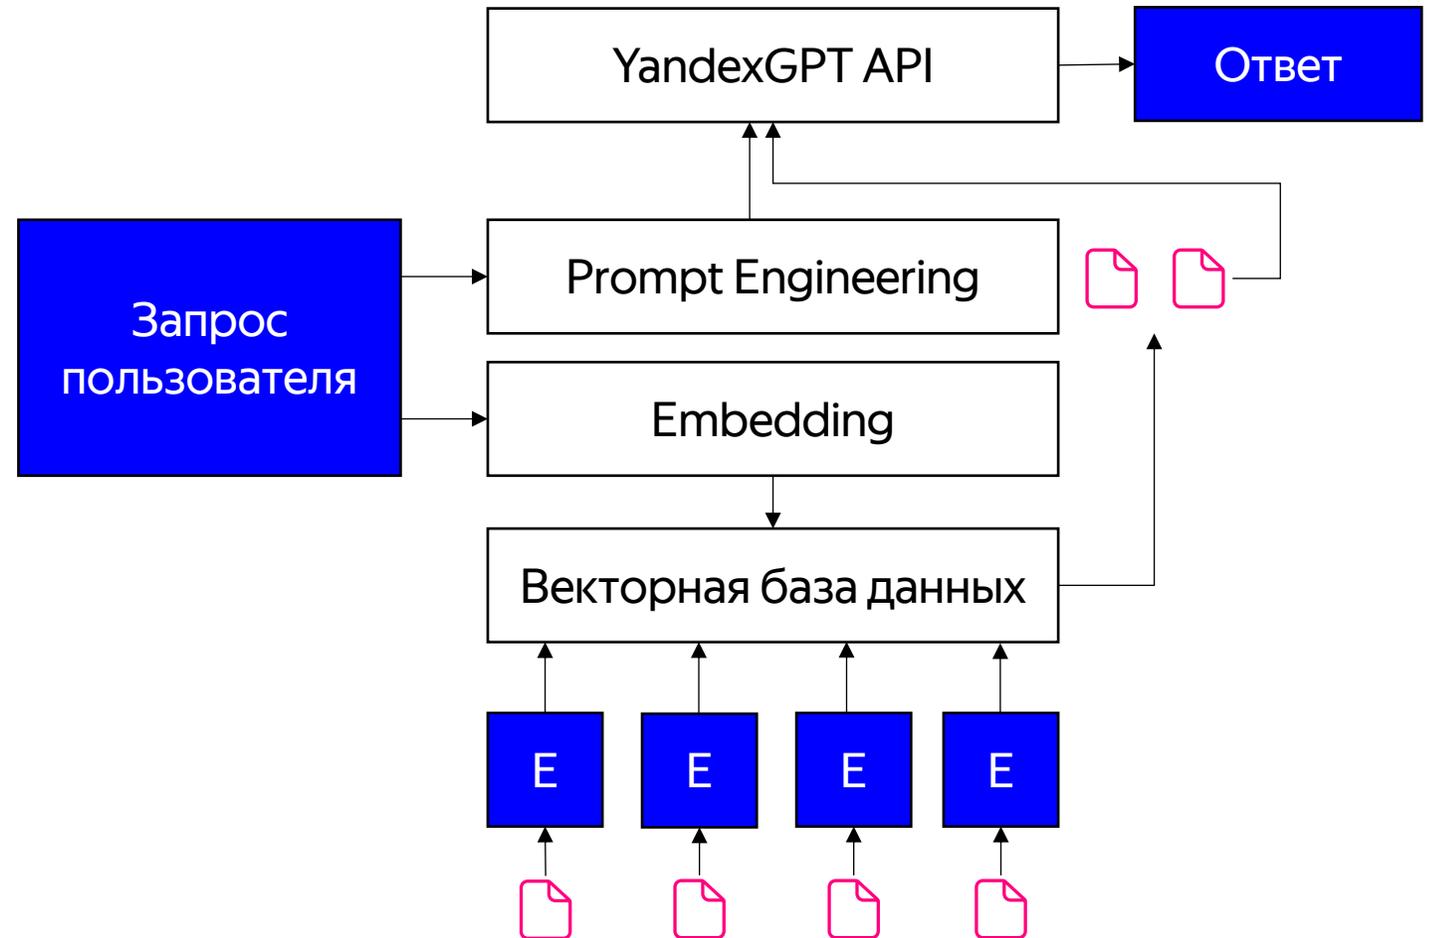
# RAG на практике (Naïve RAG)



# RAG на практике (Naïve RAG)

## Гиперпараметры:

- Размер фрагмента текста
- Размер overlap
- Промпт
- Алгоритм поиска фрагментов
- Количество фрагментов в запросе
- Используемые эмбединги



# Демонстрация

Яндекс

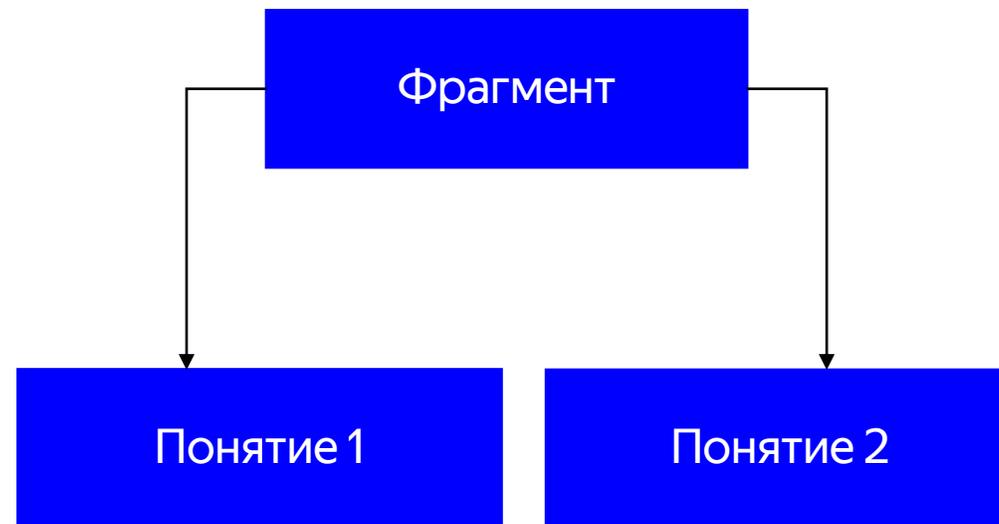


[github.com/  
yandex-datasphere/  
advanced\\_rag](https://github.com/yandex-datasphere/advanced_rag)

# Продвинутые стратегии индексации

## Parent Retriever

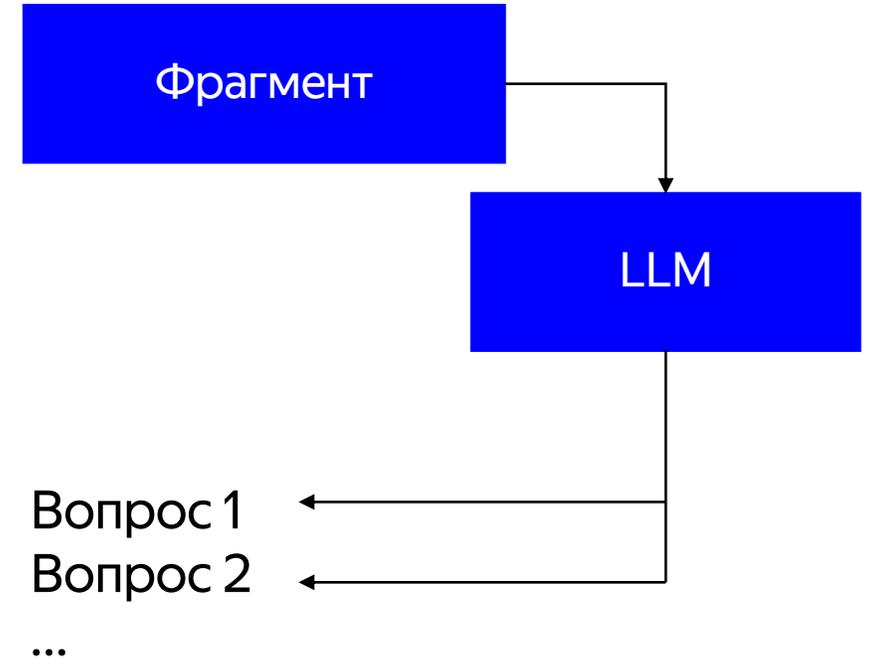
- Разбиваем фрагменты документов на ещё более мелкие фрагменты
- Parent-Child Relationship
- Мелкие документы уточняют конкретные понятия, родительские — задают более крупный контекст
- Находим ребенка, вбрасываем в контекст родителя



# Продвинутые стратегии индексации

## Гипотетические вопросы

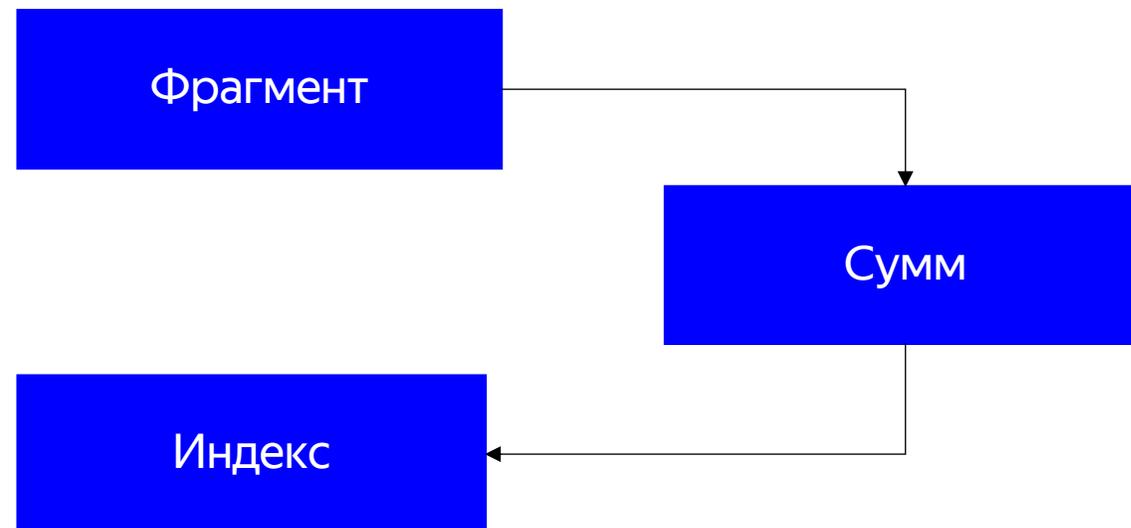
- Из фрагментов документов извлекаются вопросы, на которые эти фрагменты отвечают
- Индексируются гипотетические вопросы, вбрасываются в контекст исходные документы



# Продвинутые стратегии индексации

## Суммаризация

Индексируются суммаризованные фрагменты текста, вбрасываются в контекст исходные документы



[Блог](#) / [Новости](#) /

# YandexGPT поможет абитуриентам НИУ ВШЭ выбрать профессию

YandexGPT внедрили в чат-бот на сайте и в телеграм-канале НИУ ВШЭ. Абитуриенты могут поделиться с ботом информацией о себе и своих интересах, чтобы получить рекомендации по подходящим образовательным программам.

24 мая 2024 г.

 5 минут чтения

 Поделиться

 1

# Одна из проблем наивного RAG

## Мерло

Мерло хорошо сочетается с сыром Бри

## Каберне

Каберне хорошо сочетается с сыром Бри

...

## Сира

Сыр Бри отлично подходит к вину сорта Сира

## Вопрос:

Какие вина хорошо подходят к сыру Бри?



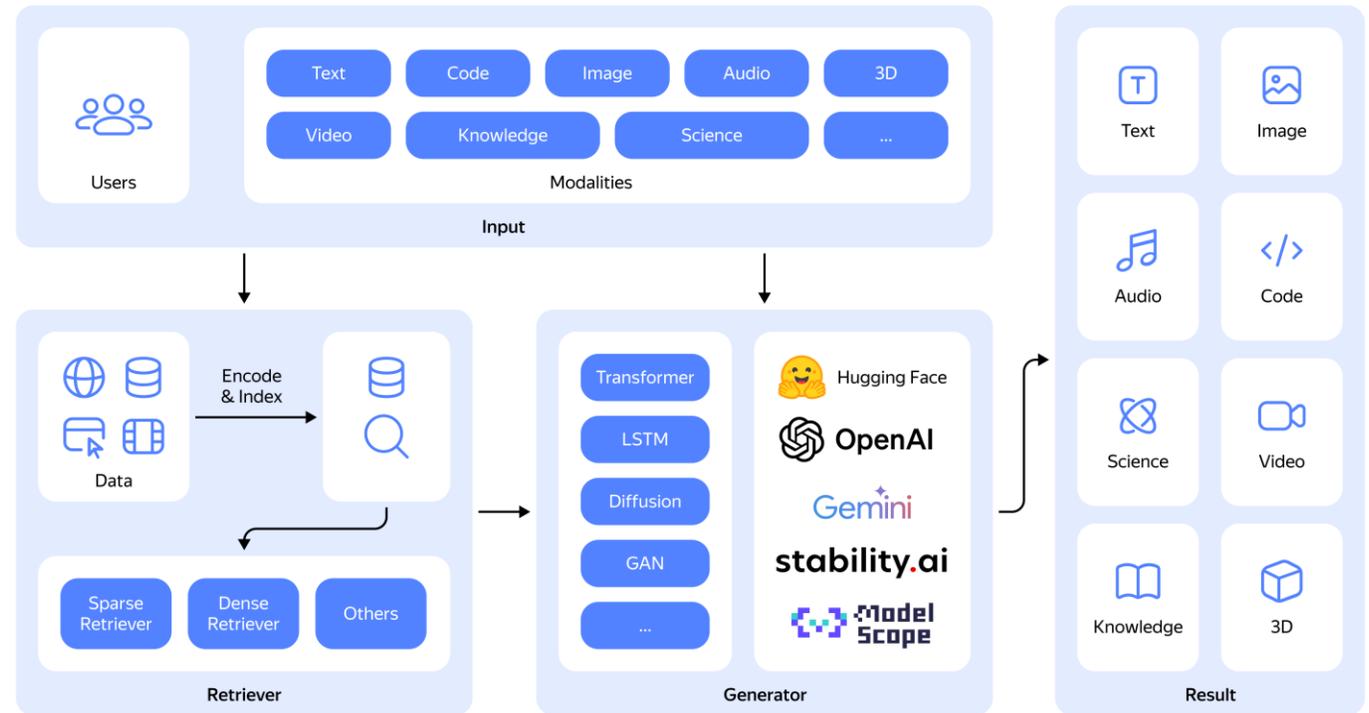
# Различные вариации RAG

## 1/ Передача Retrieval-Generator:

- Query-based
- Latent Representation
- Logit-based
- Speculative

## 2/ Улучшения

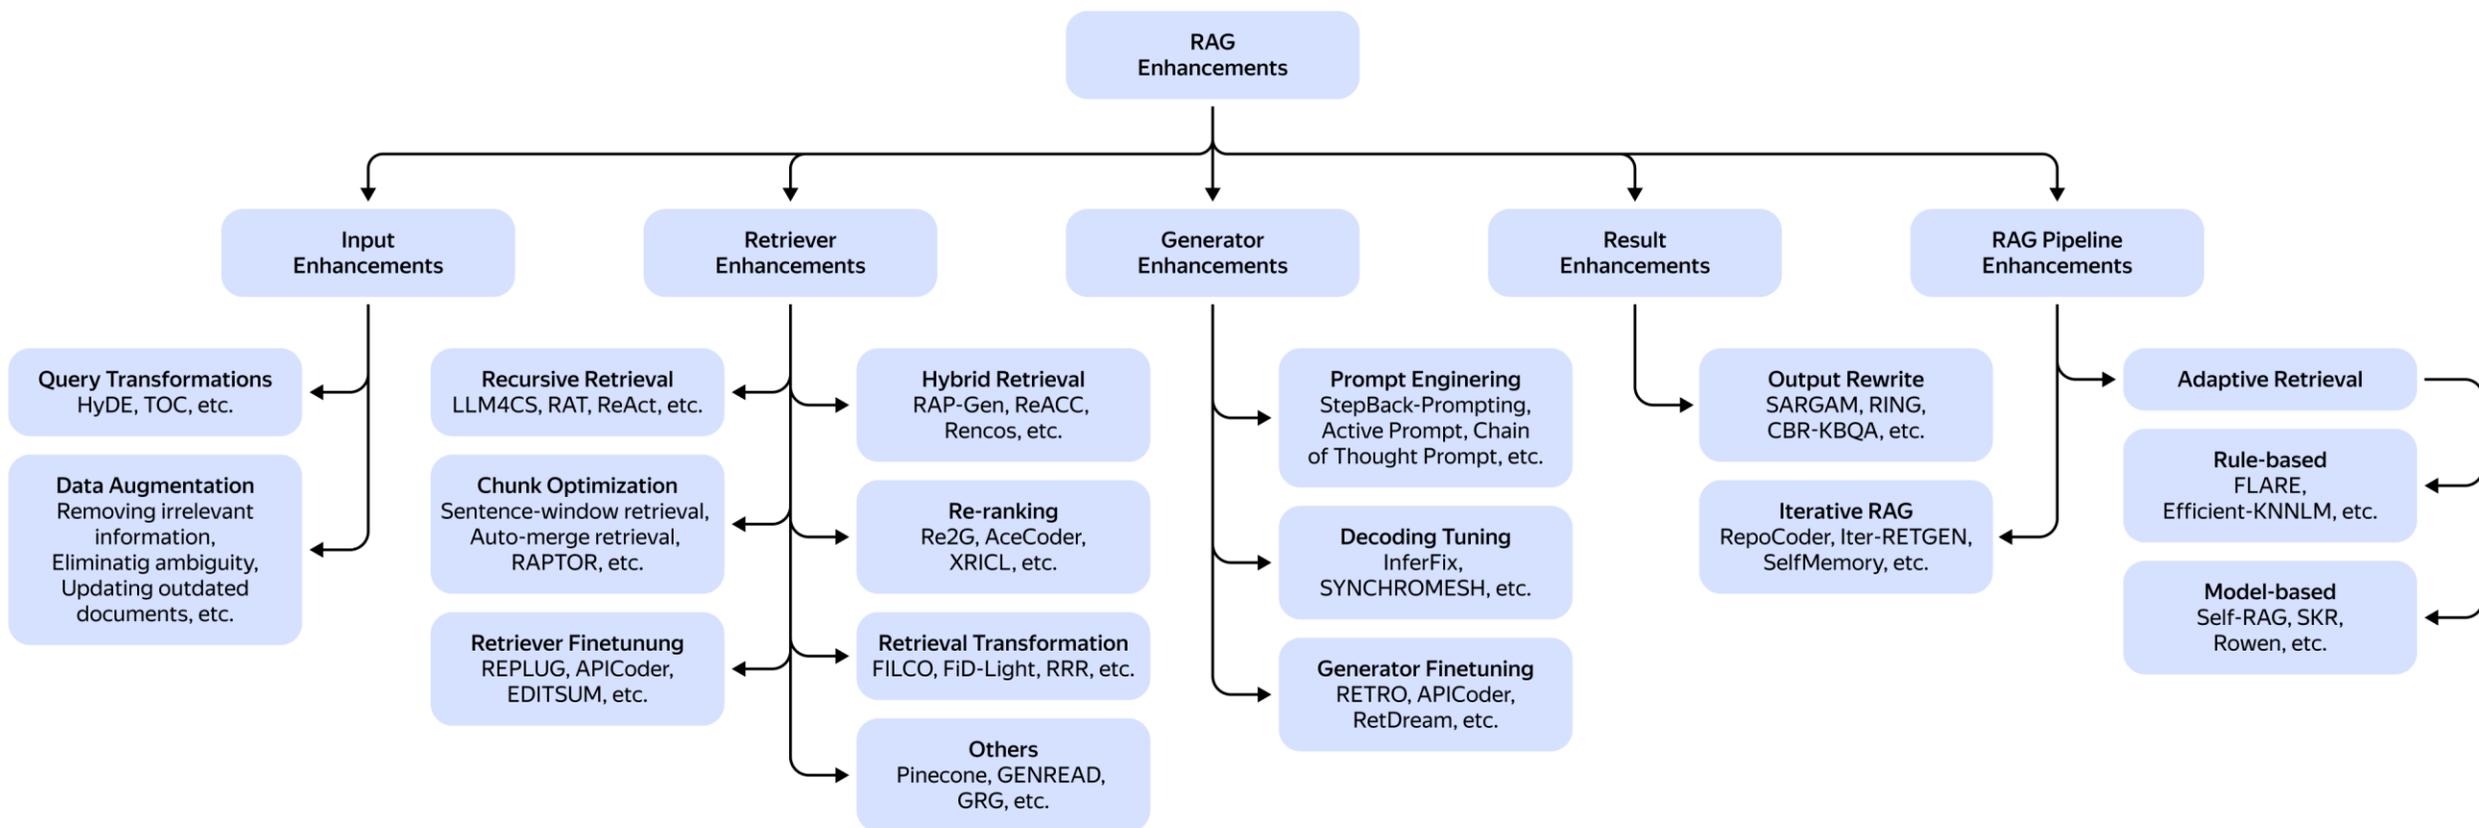
## 3/ Нетекстовый RAG



Zhao, Penghao, et al. «Retrieval-augmented generation for ai-generated content: A survey.» arXiv preprint arXiv:2402.19473 (2024).



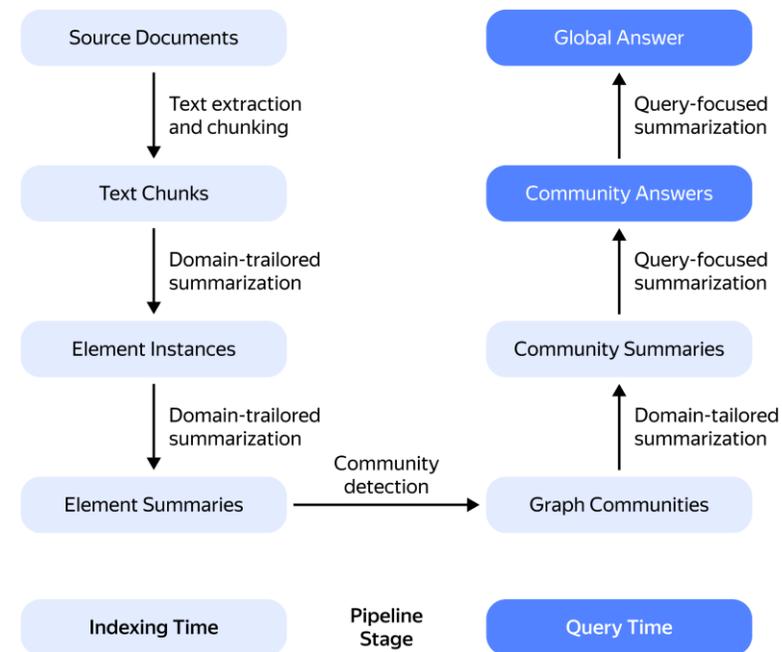
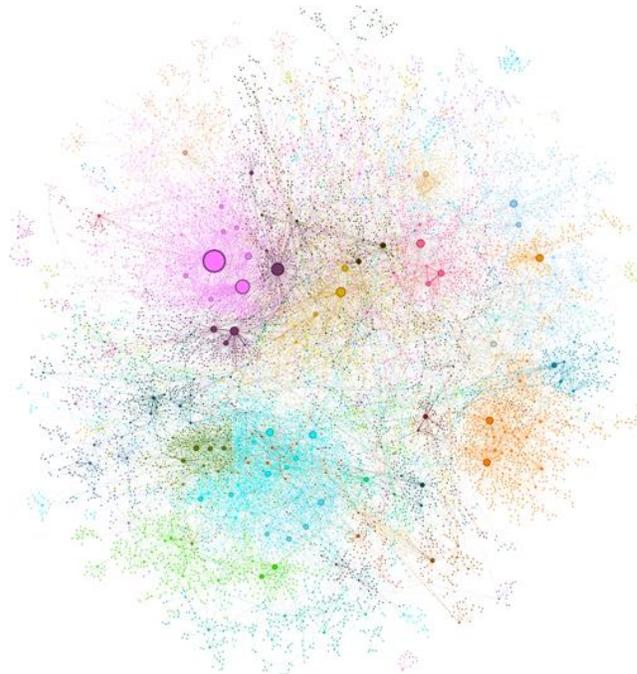
# Различные подходы к улучшению RAG



# GraphRAG

[github.com/microsoft/graphrag](https://github.com/microsoft/graphrag)

Edge, Darren, et al. «**From local to global: A graph rag approach to query-focused summarization.**» arXiv preprint arXiv:2404.16130 (2024) — Microsoft Research



# На стыке явного представления знаний и ML!

- Allemang, Dean, and Juan Sequeda. «Increasing the LLM Accuracy for Question Answering: Ontologies to the Rescue!» arXiv preprint arXiv:2405.11706 (2024)
- Martino, Ariana, Michael Iannelli, and Coleen Truong. «Knowledge injection to counter large language model (LLM) hallucination.» European Semantic Web Conference. Cham: Springer Nature Switzerland, 2023



# На стыке явного представления знаний и ML!

- Allemang, Dean, and Juan Sequeda. «Increasing the LLM Accuracy for Question Answering: Ontologies to the Rescue!» arXiv preprint arXiv:2405.11706 (2024)
- Martino, Ariana, Michael Iannelli, and Coleen Truong. «Knowledge injection to counter large language model (LLM) hallucination.» European Semantic Web Conference. Cham: Springer Nature Switzerland, 2023



# Food + Wine Ontology

```
<owl:Class rdf:ID="Merlot">
  <rdfs:subClassOf>
    <owl:Restriction>
      <owl:onProperty rdf:resource="#hasColor" />
      <owl:hasValue rdf:resource="#Red" />
    </owl:Restriction>
  </rdfs:subClassOf>
  <rdfs:subClassOf>
    <owl:Restriction>
      <owl:onProperty rdf:resource="#hasSugar" />
      <owl:hasValue rdf:resource="#Dry" />
    </owl:Restriction>
  </rdfs:subClassOf>
  <rdfs:subClassOf>
    <owl:Restriction>
      <owl:onProperty rdf:resource="#hasFlavor" />
      <owl:allValuesFrom>
        <owl:Class>
          <owl:oneOf rdf:parseType="Collection">
            <owl:Thing rdf:about="#Moderate" />
            <owl:Thing rdf:about="#Delicate" />
          </owl:oneOf>
        </owl:Class>
      </owl:allValuesFrom>
    </owl:Restriction>
  </rdfs:subClassOf>
</owl:Class>
```

```
<owl:Class rdf:ID="PastaWithSpicyRedSauceCourse">
  <owl:intersectionOf rdf:parseType="Collection">
    <owl:Class rdf:about="#MealCourse" />
    <owl:Restriction>
      <owl:onProperty rdf:resource="#hasFood" />
      <owl:allValuesFrom rdf:resource="#PastaWithSpicyRedSauce" />
    </owl:Restriction>
  </owl:intersectionOf>
  <rdfs:subClassOf>
    <owl:Restriction>
      <owl:onProperty rdf:resource="#hasDrink" />
      <owl:allValuesFrom>
        <owl:Restriction>
          <owl:onProperty rdf:resource="&vin;hasColor" />
          <owl:hasValue rdf:resource="#Red" />
        </owl:Restriction>
      </owl:allValuesFrom>
    </owl:Restriction>
  </rdfs:subClassOf>
  <rdfs:subClassOf>
    <owl:Restriction>
      <owl:onProperty rdf:resource="#hasDrink" />
      <owl:allValuesFrom>
        <owl:Restriction>
          <owl:onProperty rdf:resource="&vin;hasBody" />
          <owl:hasValue rdf:resource="#Full" />
        </owl:Restriction>
      </owl:allValuesFrom>
    </owl:Restriction>
  </rdfs:subClassOf>
</owl:Class>
```



# Многоагентные системы

- Что подавать к Мерло?
- Сколько стоит литр Мерло?
- Из какого винограда делают Мерло?



# Классификаторы на базе YandexGPT API

- Промт для YandexGPT API
- Zero-shot Endpoint
- Few-shot Endpoint
- Дообучение классификатора

Пример наполнения файла для обучения бинарной классификации:

```
{"text": "у меня все в порядке", "нейтральный": 1, "эмоциональный": 0}  
{"text": "у меня все классно получилось ", "нейтральный": 0, "эмоциональный": 1}  
{"text": "вам не понять как тяжело бывает каждый день вставать на работу в шесть утра и два часа тащит  
{"text": "все как всегда работа дом семья", "нейтральный": 1, "эмоциональный": 0}
```

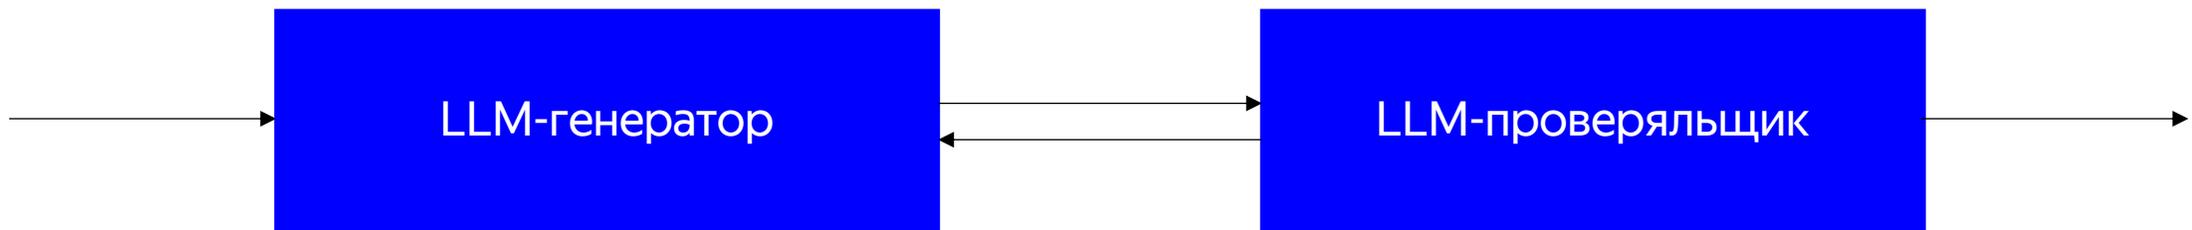
```
{  
  "modelUri": "string",  
  "taskDescription": "string",  
  "labels": [  
    "string",  
    "string",  
    ...  
    "string"  
  ],  
  "text": "string",  
  "samples": [  
    {  
      "text": "string",  
      "label": "string"  
    },  
    {  
      "text": "string",  
      "label": "string"  
    },  
    ...  
    {  
      "text": "string",  
      "label": "string"  
    }  
  ]  
}
```



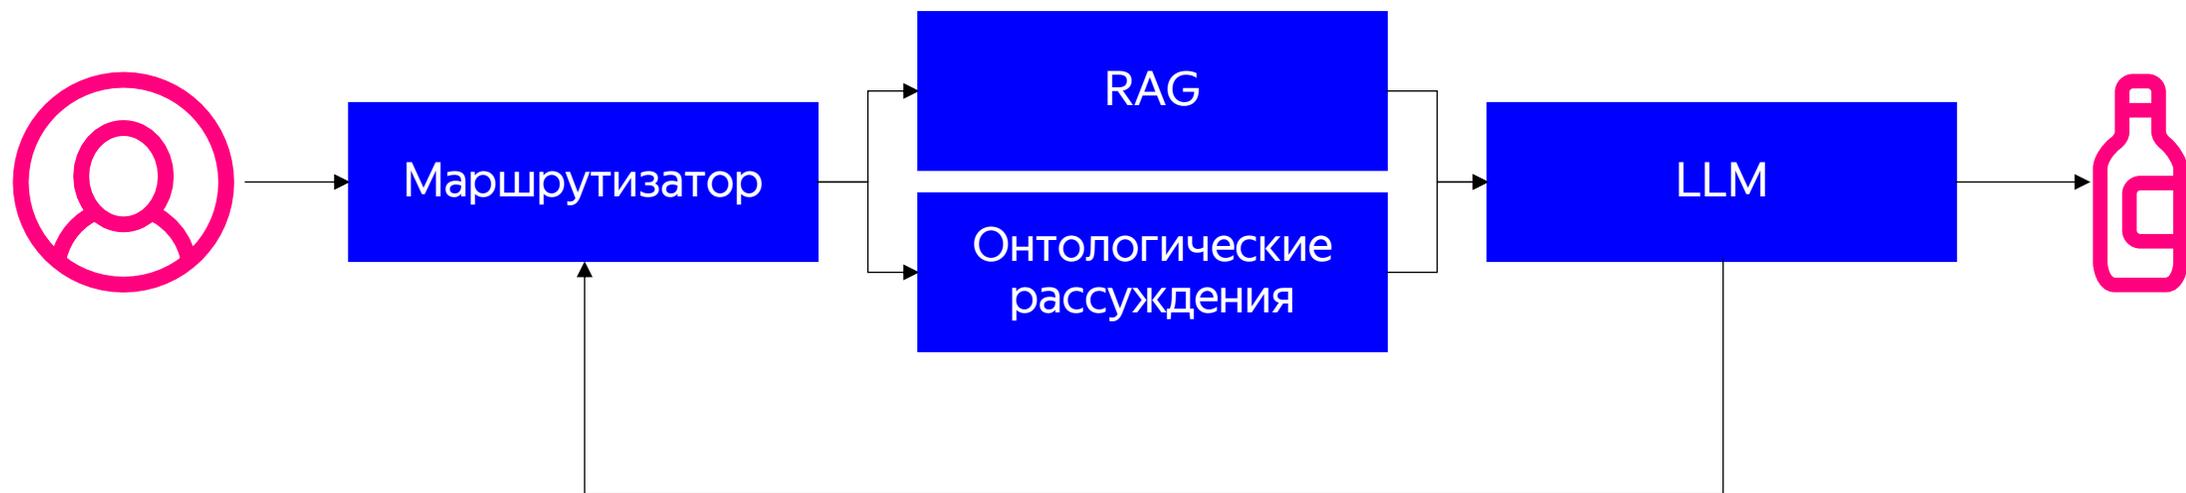
# Проблема с рассуждениями у LLM

[Sébastien Bubeck](#), [Varun Chandrasekaran](#), et.al. Sparks of Artificial General Intelligence: Early experiments with GPT-4 [arXiv:2303.12712](#) [cs.CL]

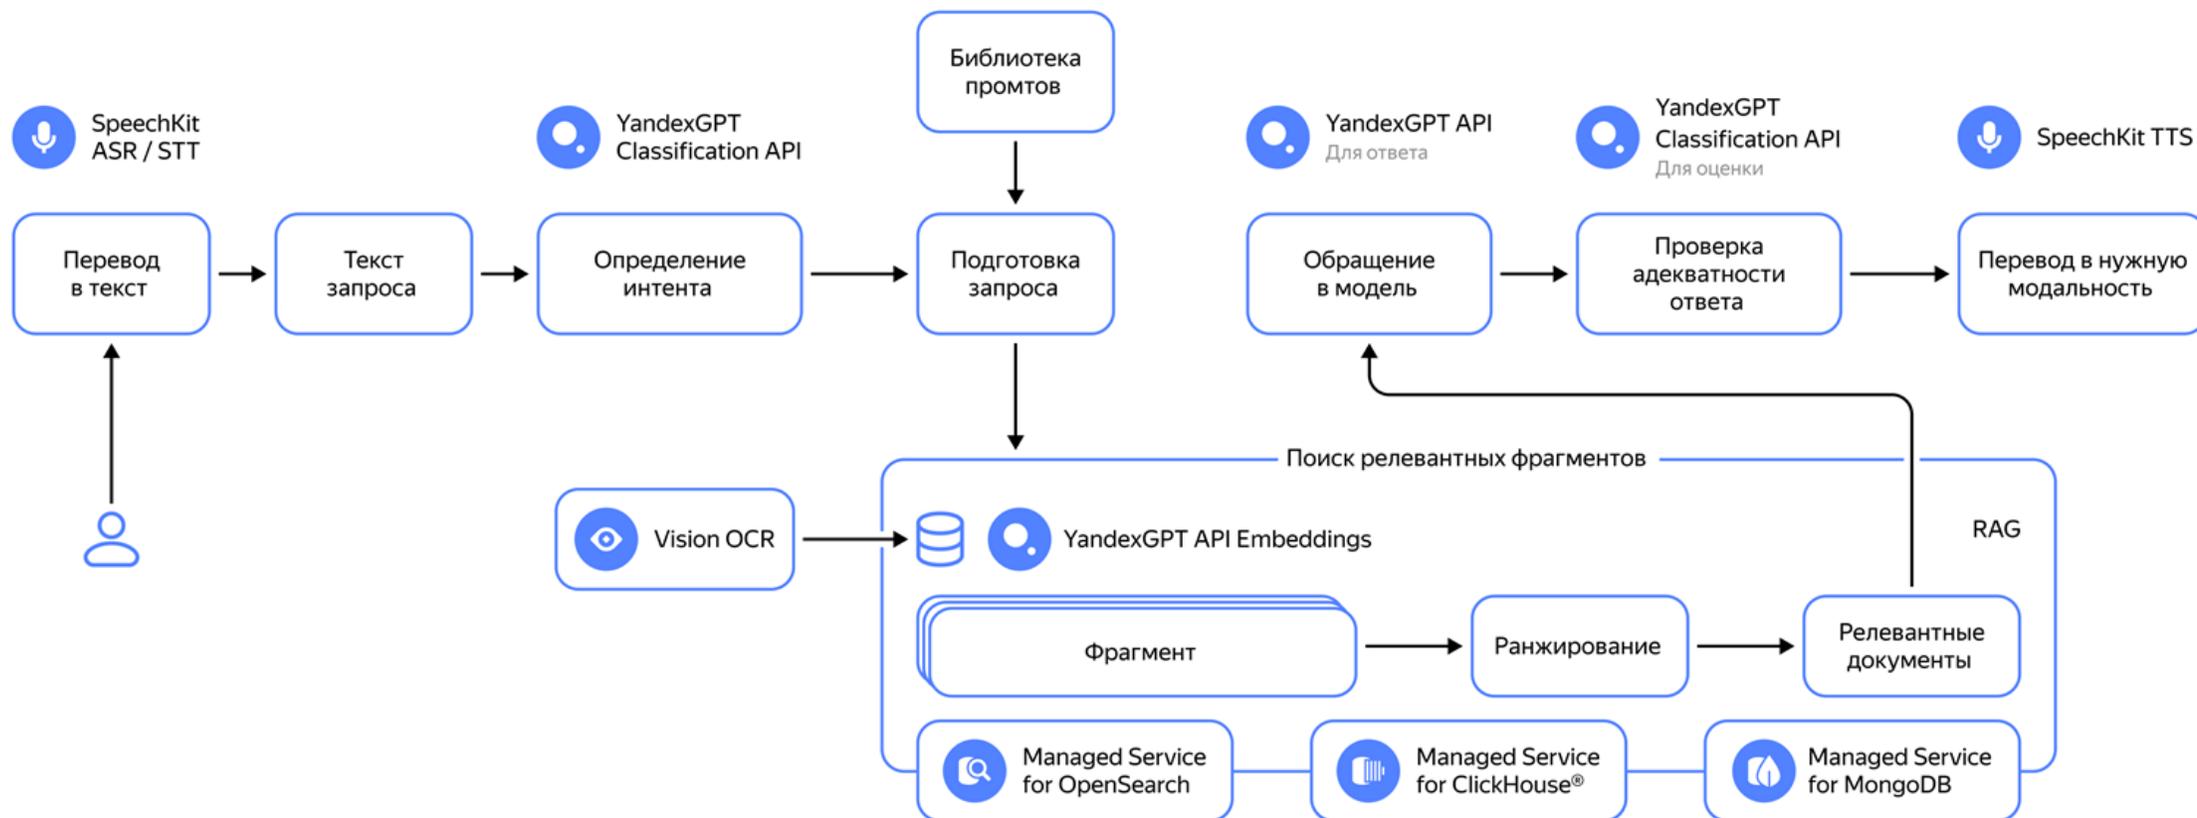
**Основная проблема** — линейный характер модели предсказания слов, отсутствие возможности размышлять с возвратами, в стиле «генерация и проверка»



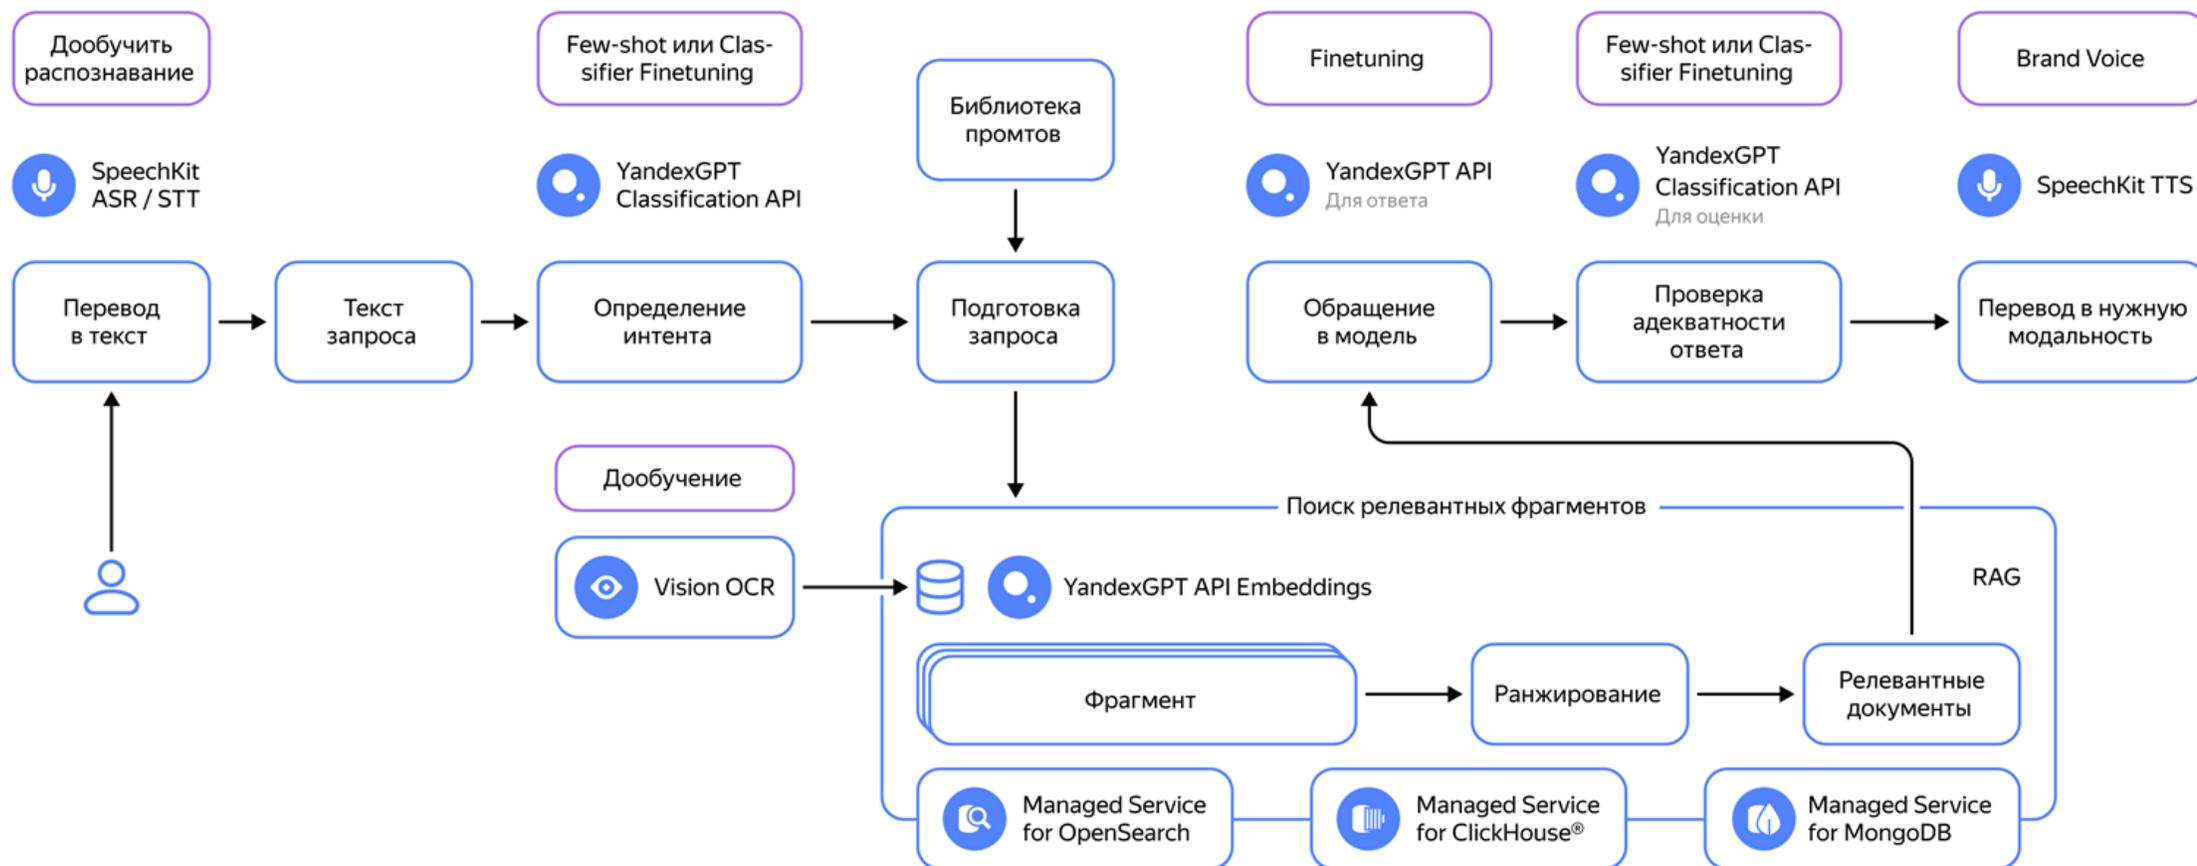
# Многоагентные системы с верификацией



# Архитектура

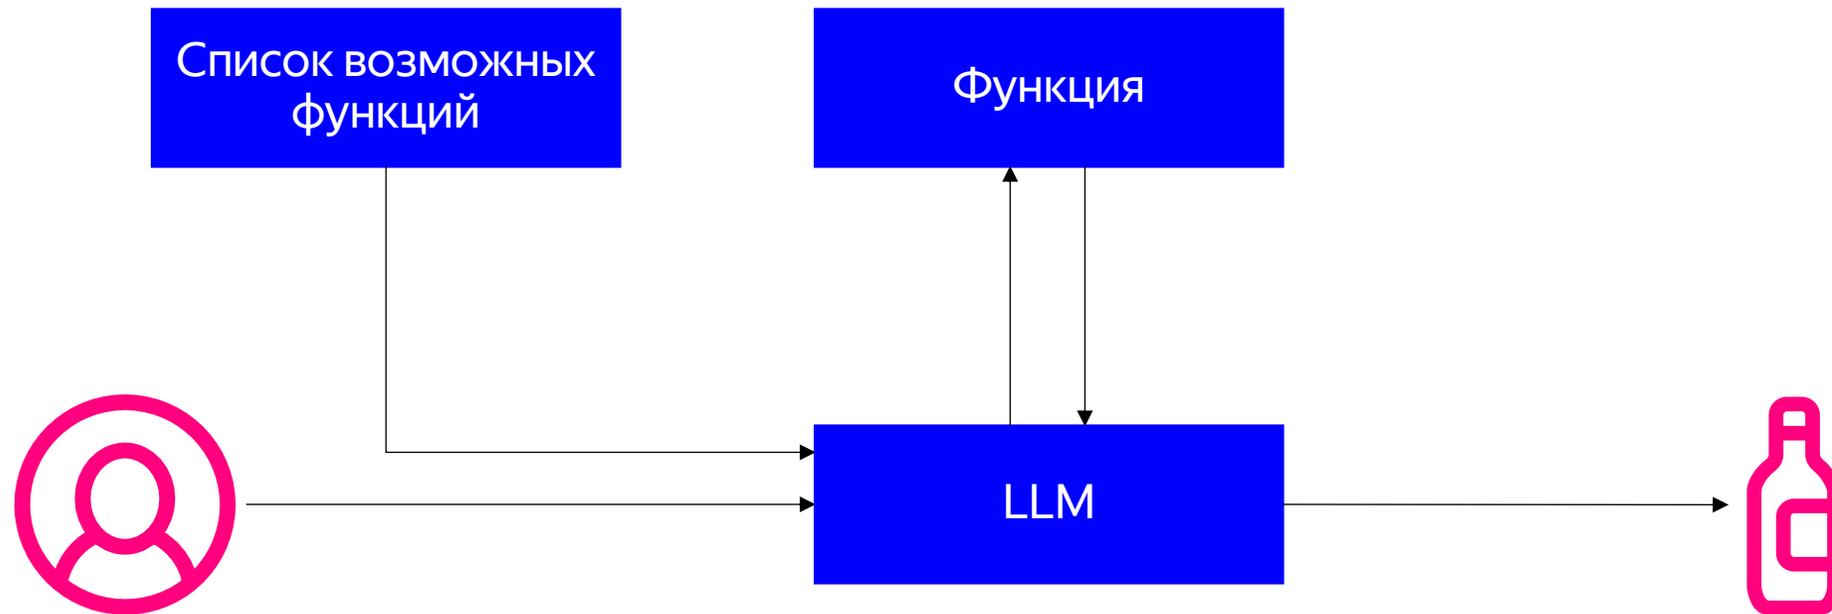


# Архитектура



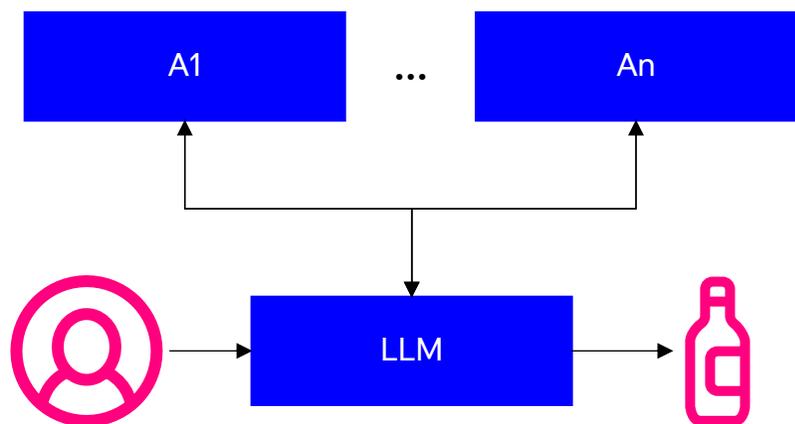
# Function Calling

Что лучше есть с самым известным вином из Австралии?

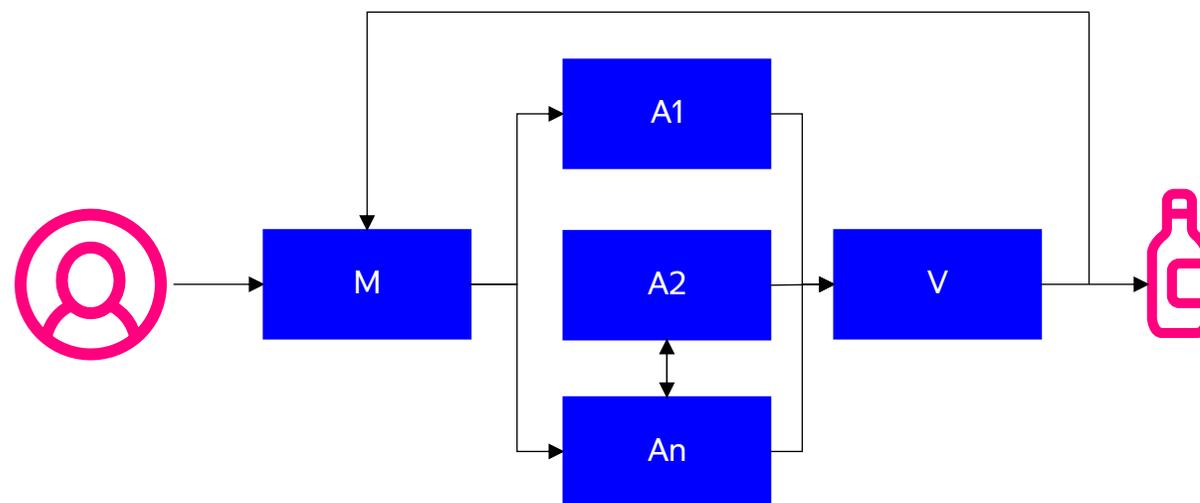


# Два подхода к оркестрации MAS

LLM-оркестрация (Function Calling)



Ручная оркестрация



# Обзор разных подходов к аугментированию LLM

## 01/

### Reasoning [=Problem Decomposition]

- CoT
- Recursive Prompting

## 02/

### Using Tools

- Information Retrieval
- Navigating the Web
- Symbolic Models and Code Interpreters
- Acting
- Calling Other Models

## 03/

### Learning to Reason and Use Tools

- Supervision
- Reinforcement Learning



# Эволюционная кибернетика

Принцип метасистемного перехода и эмерджентность



# Эволюционная кибернетика

## Принцип метасистемного перехода и эмерджентность



# Эволюционная кибернетика

## Принцип метасистемного перехода и эмерджентность



# Мораль

## 01/

Различные подходы к обогащению LLM с помощью внешних знаний позволяют подобрать подход, оптимальный для решения конкретной задачи

## 02/

Graph RAG — это движение в сторону объединения неявного (LLM) и явного (графы, онтологии, семантические сети) представления знаний, в большей интерпретируемости

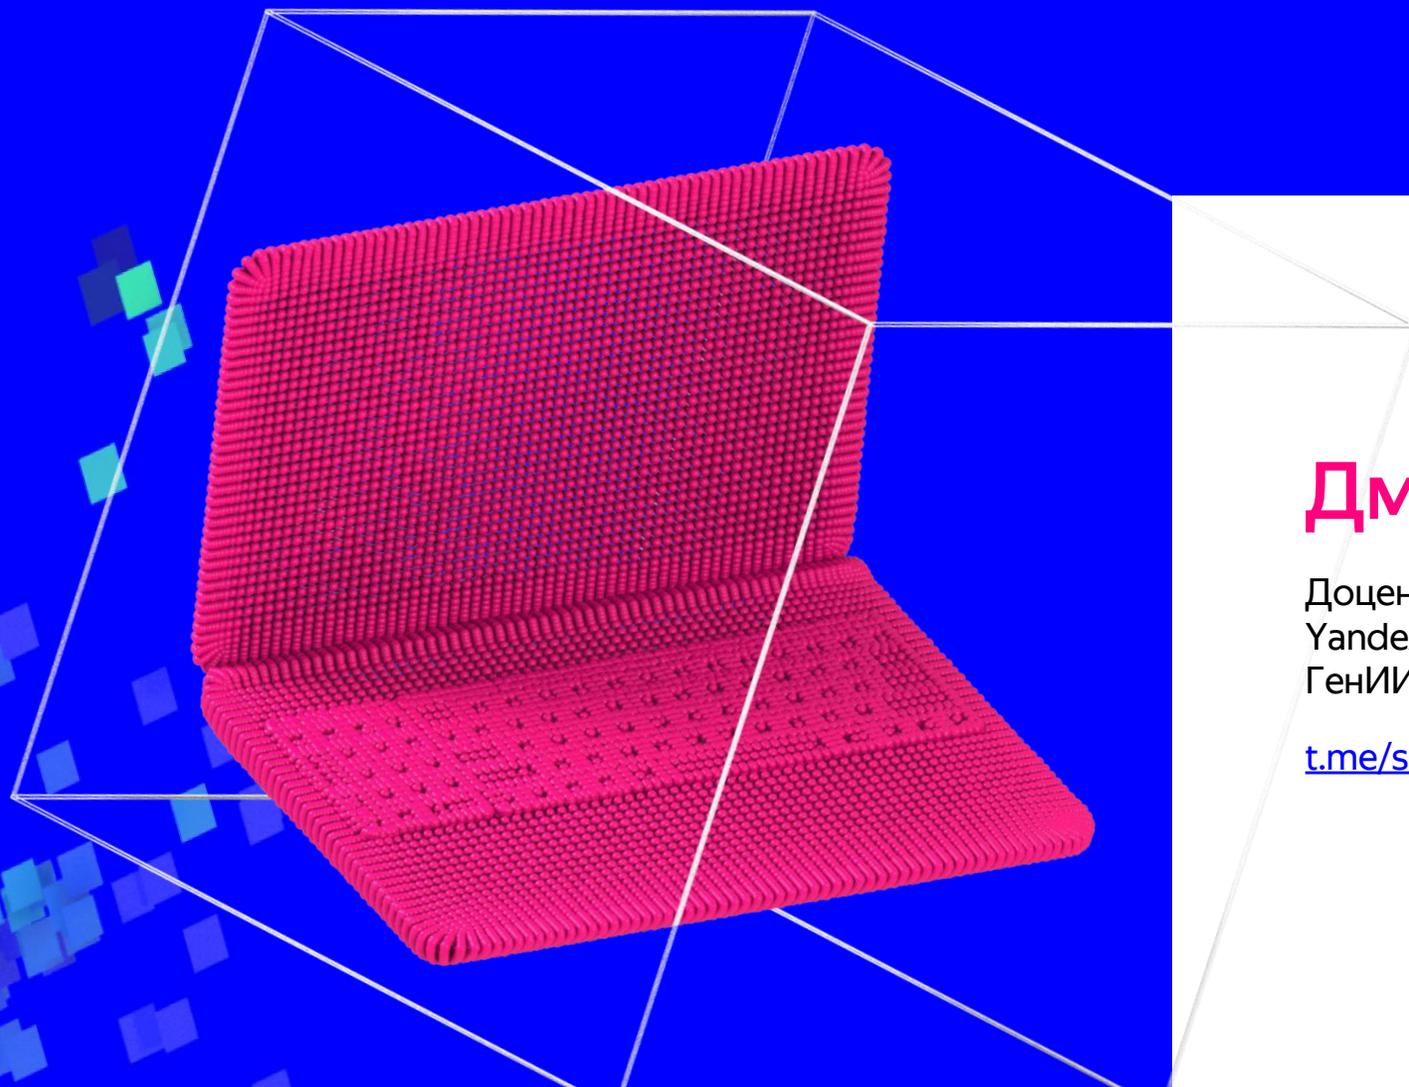
## 03/

LLM вдыхают новую жизнь в теорию мультиагентных систем. За счет синергетического эффекта MAS позволяют улучшать результаты LLM, хотя иногда за счет существенного увеличения стоимости



# Спасибо за внимание!

Яндекс



## Дмитрий Сошников

Доцент НИУ ВШЭ/МАИ, консультант  
Yandex Cloud, тех. руководитель лаборатории  
ГенИИ Школы дизайна НИУ ВШЭ

[t.me/shwarsico](https://t.me/shwarsico)

