

ИЮНЬ 2024

Генеративный ИИ – новый драйвер экономического роста

Алена Стемпаржевская | Руководитель направления развития бизнеса AI, SberDevices

Ключевые моменты в развитии технологий



Персональные компьютеры

20 лет



Интернет

12 лет



Мобильные приложения

6 лет




AI

~ 3 года

Период адаптации

LLM значительно приблизили выход AI на «человеческий» уровень

Достижение AI уровня 25% топ-перформеров




2030

AI будет работать на среднем уровне человеческой производительности

2040

AI станет высокопроизводительным помощником человека



SberDevices — технологический вендор в Сбере

Нейросетевая модель

GIGA CHAT



Цифровой офис



Телевизоры Sber
21 модель, 32" — 75", OLED,
4K, Full HD,
HD Ready

Умные устройства

Умный дом



SberBoom &
SberBoom Mini



SberPortal



SberBox
Time



SberBox



- Салют, GigaChat

от 8К контекст

= 12 страниц А4

GigaChat Lite(+) – 8/32к контекст – быстрая, для реализации базовых сценариев

GigaChat Pro – 8к контекст – для выполнения сложных инструкций и специальных доменных


Embedder – для векторного представления текста

50 / 50

Side-by-Side
GigaChat-29B vs. ChatGPT-3.5

63,2

Massive Multitask Language Understanding
(MMLU) Benchmark



7.5 ПБ

Это 47 Российских государственных библиотек

...или как если бы мы обработали всю литературу в мире 2,5 раза

1024
GPU

Для обучения модели

4 мес. можно было бы снабжать электричеством весь стадион Лужники

Варианты работы с GigaChat



**GIGA
CHAT**

**Удобный пользовательский
интерфейс**

Общение с моделью в удобном формате в web-версии, Tg или VK

- Быстрая генерация идей
- Создание текстов
- Рисование картинок по текстовому описанию

**Первый
шаг**



**GIGA
CHAT
API**

Прямой запрос к AI модели

Для работы с базовой моделью «из коробки», при помощи инструкций

- Генерация
- Суммаризация
- Ответы на вопросы

**Составление
инструкций**



**GIGA
CHAIN**

**Адаптация модели к бизнес-
сценариям**

Для «дообучения» модели данными компании и взаимодействия с внутренними системами

- Ответы по документации
- Чат-бот
- Суммаризация больших текстов

Создание сценариев



**GIGA
CHAT
inside**

**Готовое решение со
встроенной AI моделью**

Для решения конкретных задач бизнеса GigaChat уже интегрирован в ряд решений на рынке

- CRM
- RPA – платформа
- Офисное ПО
- Сервисы аналитики

Готовые решения

Решения с уже интегрированной AI-моделью

SIGA
CHAT
inside



SaluteBot

Интеллектуальные чат-боты для обработки обращений клиентов и сотрудников без участия человека.

Обогащение реплик чат-бота, автоматизация диалогов



SaluteSpeech

Платформа для распознавания и синтеза речи.

Её технологии расшифровывают, озвучивают и превращают текст в аудиодорожку.

Генерация текста для озвучивания



SberJazz

Сервис для общения, работы и обучения.

Можно создавать видеовстречи любой продолжительности и переписываться во встроенном мессенджере.

Суммаризация итогов встречи

SaluteRPA & IDP

Программные роботы для автоматизации бизнес-процессов.

Помогут оптимизировать ресурсы сотрудников и сократить затраты на рутинные операции.

Диалог с документами в режиме чата



Чат-платформа для связи с клиентами: чат на сайте, соцсети, мессенджеры и звонки.

Подсказки для оператора, быстрые ответы на сообщения пользователей

Какие задачи подходят для LLM уже сегодня

Исполнение инструкций

Выполнение поэтапных преобразований текстовых данных

Например:

- Перепиши текст [...] в более формальном стиле
- Напиши сопроводительное письмо для рекламной кампании соблюдая структуру [...]
- Составь ответ на обращение с учетом установленного регламента

Анализ данных

Например:

- Проанализируй текст и присвой тэги из базы

Структурирование информации

Помощь в написании запросов и при извлечении информации

Например:

- Напиши запрос в SQL для таблицы [...] сколько заработал [ФИО] за 2020?
- Найти в Уставе коды ОКВЭД

Работа с контекстом

Понимание текста и ответ на вопрос с подсказкой системы – контекстом, индексом – для работы с большим количеством данных

Например:

- Основываясь на данных из [...], определи основные тренды развития компании
- На базе [...], сформируй список наиболее часто задаваемых вопросов

Какие еще задачи решает GigaChat

Генеративный поиск по базе знаний

Пользовательский интерфейс, где пользователь задаёт вопрос в текстовом виде и получает текстовый ответ и ссылку на документ, в котором этот ответ был найден.



**GIGA
CHAT**

Автоматизация обслуживания

Облегчение работы по созданию и эксплуатации ботов и диалоговых ассистентов

Речевая аналитика

Обработка больших массивов коммуникаций, используя запросы на естественном языке

Определение параметров и поиск аналогов

Пользовательский интерфейс, где пользователь указывает текстовое название оборудования и получает карточку с заполненными параметрами номенклатурных позиций из ГОСТ.


GIGACHAT

ПРОМПТ ИНЖИНИРИНГ



Работа с LLM GigaChat

Промт-инжиниринг, сценарии,
GigaChain, системные промты, RAG и
многое другое 😊



Пройдите курс по обучению
работе с моделью и становитесь
продуктивнее уже сегодня

Какой вклад генеративных нейросетей возможен? SBER DEVICES

Создание персонализированного контента

через знания о клиентах и их предпочтения, а также за счет формирования синтетических данных

Формирование подборок и нестандартная классификация

альтернативный поиск по неформальным описаниям (специфика семантического и ассоциативного ряда)

Структурирование информации

быстрый анализ и суммаризация различных объемов данных

Эмерджентность нейросетей

случайно открываемые новые способности модели, которым специально ее не обучали

Исполнение инструкций

обработка обратной связи клиентов, преобразование текстовых данных и их систематизация



Сценарии



КЕЙС 1

Генеративный поиск по базе знаний

ПОИСК по базе знаний

CROSS-INDUSTRY RE-USE

GIGA CHAT

ЦИФРОВОЙ

Задача:

Повысить скорость и качества поиска информации по базам данных компании.




Срок реализации: ~16 недель




Команда: ~18 человек

Сложность реализации:



Средний

Потенциальный эффект:




Средний

Решение:

Система умного поиска по базам знаний на основе архитектуры RAG.

Затраты на инфраструктуру:

Отсутствуют



Результат:

Кратное увеличение качества поиска
Точность ответов **90%**



КЕЙС 1

Co-pilot финансового аналитика

Co-pilot финансового аналитика в промышленном предприятии

GIGA
CHAT

ЦИФРА
БЕЗУСЛОВИЮ

CROSS-INDUSTRY
FEASE

Задача:

Сократить время
подготовки
факторного
анализа
отклонений МД



Срок реализации:
~18 недель



Команда:
~10 человек

Сложность реализации:



Средний


Потенциальный эффект:



Средний

Решение:

Вопрос-ответная система по базе
аналитических данных. GigaChat
преобразовывает запрос на естественном
языке в SQL-запрос и возвращает точную
цифру из базы данных.



Результат:

Кратное увеличение скорости анализа данных
Повышение качества принятия решений
Точность ответов 92%

Варианты поставки

Широкие возможности модели поставки

Клиенты	МСБ / ISV	Крупный и крупнейший бизнес / Гос. (через Solution-партнеров)			
Тип поставки	Cloud		On-prem		
Продукт	 Giga Public  Giga Platform	 Giga Private  +  Giga Platform Аренда железа в облаке	 Giga OnPrem  +  Giga Platform Evolution/ Giga Stack (на железе компании)	 Giga Server  +  +  Giga Platform Evolution/ Giga Stack Сервер	 Giga Cube  +  +  Giga Platform Evolution/ Giga Stack Серверная стойка
Монетизация	Плата за использование	Аренда Private Cloud	Лицензия	Продажа / аренда оборудования	
	RevShare с продажи конечных продуктов на основе GigaPlatform (гипотеза)				

ПАК GIGA CUBE или самостоятельная разработка?

Использование open-source моделей

Лицензионные ограничения и неадаптированный alignment

Нет оптимизации под инференс (увеличение требований к «железу»)

Нет гарантии обратной совместимости при обновлении

Нет возможности добавить в pretrain новые знания

Разработка большой языковой модели с нуля

Собрать данные для pretrain (Петабайты)

Подготовить и разметить инструктивный датасет

Построить суперкомпьютер для обучения модели (множество итераций и тысячи GPU)

Сформировать пайплайн обучения (эксперименты на GPU по несколько месяцев)

10+ млрд ₺

инвестиции

3+ года

время

Преимущества ПАКа GIGA CUBE

Навыки модели адаптированы к потребностям бизнеса

x18

адаптация к русскому языку

x100

экономии

x50

ко времени

Стратегия: «от ускорения отдельных задач к E2E цифровым функциям»

РОСТ ПРОИЗВОДИТЕЛЬНОСТИ

Ускорение отдельных задач

поиск информации, подготовка холодного письма, суммаризация документа

Рост производительности:



Suit для конкретной роли / функции

Консультант-продавец

Рост производительности:



Цифровой сотрудник

сам ставит себе задачи, сам исполняет в рамках конкретной роли, конкретной отрасли

Рост производительности:



Цифровая функция

E2E-функция

Рост производительности:



2023-24

2024-25

2025+

УРОВЕНЬ ЦИФРОВИЗАЦИИ ФУНКЦИИ

Присоединяйтесь к GigaChat

