



ИИ вам не поможет

Или как построить бота, который реально работает



Дмитрий Лосев

Продакт-менеджер, iQStore





О компании

iQStore (ООО «АЙ КЬЮ СТОР») – российская ИТ-компания, входящая в состав крупного консорциума iCAM Group и занимающаяся разработкой программных решений для создания бесшовного клиентского сервиса. Экспертиза компании – омниканальные коммуникации и автоматизация обслуживания с применением искусственного интеллекта.

14 лет

исследований и разработок

50+

клиентов крупного бизнеса

15+

решений для бизнеса

150+

успешных проектов

Боты первой линии сменили поколение, но проблемы остались

Сценарные

кнопки и ветки сценария

Как сменить ПИН-код карты?

Выберите раздел

Карты

Вклады



NLU

распознают намерение, отвечают шаблоном

Как сменить ПИН-код карты?

ПИН-код можно сменить в банкомате или интернет-банке

А если карта цифровая?

ПИН-код можно сменить в банкомате или интернет-банке



ИИ-боты

свободный текст по базе знаний


Как сменить ПИН-код карты?

Вы можете бесплатно сменить ПИН-код в интернет-банке, в банкомате или на кассе банка. В интернет-банке новый код придёт в СМС, а в банкомате вы сможете задать его самостоятельно.

Ожидание рынка: взять модель помощнее – и бот заговорит

Реальность: без правильной архитектуры ошибается даже мощная модель

Шаг 1: простой вариант, который действительно работает



Проверили на реальных данных:

98 вопросов
клиентов банка

2 модели: малая (8B)
и средняя (27B)*

107 диалогов
по три хода

5 сборок бота:
от 2 до 6 блоков

* 8B и 27B – 8 и 27 млрд. параметров

Разница в точности – **минимальна**, разница в цене – **втрое**



Стоимость железа

малая



×1

средняя



×3



Верных ответов*

малая



55%


средняя



61%

Готовы ли вы платить за разницу, которую клиент не заметит?

* 98 реальных вопросов клиентов банка, схема «база + модель»





Почему на демо всё **работает**, а в реальности – **нет**?

Потому что клиенты:



Пишут своими
словами



Уточняют



Не только
спрашивают



Задают
опасные
вопросы

Демо-вопрос ≠ реальный клиент.

Ответ в базе есть, но **бот его не находит**



2 раза из 8

нужный раздел попал в выдачу



3 раза из 8


ответил «не нашлось информации»



2 раза из 8

неверный ответ по другому разделу

Дело не в размере модели, а в формулировках.



Шаг 2: подготовка запроса дешевле, чем новая модель

Мы не меняем модель. Мы меняем то, что ей приносим.



Подготовка запроса решила проблему, с которой не справилась средняя модель.

Правильные фрагменты важнее **большой модели**



+6 п.п.

дала модель втрое дороже



+24 п.п.


дала подготовка запроса без смены модели




8 из 8

запросов теперь решаются верно

Что выгоднее – купить модель втрое дороже
или добавить слой подготовки запроса?



* 98 реальных вопросов клиентов банка



Без истории **бот теряет нить**



Что хотел узнать клиент

Ставку по накопительному счёту для Москвы



Что ушло в поиск

Только «я из Москвы» – ни слова про ставку




Что ответила средняя модель

Поздоровалась и попросила уточнить вопрос

Модель не получила историю диалога.

Шаг 3: контекст диалога или как не потерять смысл на втором вопросе



Реплика клиента:

Я из Москвы

А сколько по времени?

Как заблокировать карту?

Что уходит в поиск:

Какая ставка по накопительному счёту для клиентов из Москвы?

Сколько по времени занимает перевыпуск карты?


Как заблокировать карту? – без изменений

Решение блока:

дописать тему

дописать тему

новая тема



Один и тот же бот – два разных результата

Всё решает контекст диалога.

57%

в среднем по трём ходам
без блока контекста

40%

на втором ходу
без блока контекста

93%

на втором ходу
с блоком контекста

Качество измеряется по номеру хода.
Средняя цифра прячет провал.

Не каждая реплика – вопрос к базе



Что пишет клиент?

«Спасибо», «Понял», «Соедини с оператором»



Что делает бот?


Ищет ответ в базе знаний, потому что не умеет различать намерения




Что получает клиент?

Шаблон, прочерк, раздражение


Бот не понимает, чего хочет клиент.




Шаг 4: определяем намерение клиента прежде, чем искать информацию



Результат:



Бот выдал наши условия за чужие



Поиск

Статьи про накопительный счёт, релевантность 0,70



Проверки

Пройдены: ответ по фрагментам базы




Итог

Ложные сведения о другом банке от имени нашего

Релевантность $\neq$ правильность.

Шаг 5: проверка ответа, чтобы ни одной ошибки не ушло клиенту



Цена проверки: 2 лишних отказа +3 обращения к модели +10 сек на ответ

Честный отказ – дешевле ошибки.

Клиент судит по худшему ответу

Ради чего автоматизируем:



ответ ночью



ответ в выходной



за секунды, без очереди

Оценка результата:

Мы – средним по всем клиентам

79%

верных ответов в среднем

93%

на втором ходу диалога

≠

Клиент – своим худшим ответом

1

ответ – тот, который не сработал



звонит в банк или уходит

Что спросить у подрядчика, чтобы не купить демо



Реальные обращения

Как бот отвечает на наших вопросах, а не на демо?



Метрики по ходам

Какое качество на втором и третьем ходу диалога?



Не только вопросы

Что бот делает со «спасибо» и просьбой об операторе?



Неверные ответы

Сколько их – отдельно от честного «не знаю»?



Проверка ответа

Что проверяется перед отправкой клиенту?



Работа с базой

Как база учит слова ваших клиентов?



Благодарим за внимание

Подписывайтесь на наши каналы



 +7 (495) 120 31 82

 info@iqstore.ru

 iqstore.ru