

TrifonAI — персональная локальная ИИ-платформа

История разработки: от одного Python-скрипта до агентской платформы с памятью, десятью инструментами, веб-интерфейсом и собственной иконкой в Dock. Написано как ретроспектива — с датами, багами и настоящими причинами.

ВЕРСИЯ	ИНСТРУМЕНТОВ	ДВИЖОК	ЖЕЛЕЗО
v1.2	10	qwen3:8b	M4 · 16 ГБ

1. Вступление

INTRODUCTION · WHAT TRIFONAI IS

TrifonAI — это не чат-бот. Чат-бот — это интерфейс к языковой модели; здесь всё наоборот. Языковая модель — сменная деталь внутри платформы, которая существует независимо от неё.

Ключевая философия проекта формулируется одной фразой: **интеллект, память и инструменты принадлежат платформе, а не модели**. Модель — это вычислительный движок, который сегодня qwen3:8b через Ollama, а завтра может быть любым другим. Долговременная память, характер, набор инструментов, правила поведения — постоянны и живут в коде и в базе, а не в весах модели. Заменить движок — не значит потерять ассистента.

Второй принцип — **полная локальность**. Всё работает на MacBook Air M4 с 16 ГБ памяти: модель, база данных, веб-сервер. Наружу не уходит ничего — единственное исключение появилось позже и осознанно: инструмент веб-поиска, который по определению обращается в интернет.

Проект начинался с другой нейросети в роли ассистента разработки. В какой-то момент контекст проекта был передан Claude — со всей историей, архитектурой и решениями, — и дальше работа шла уже с ним, сначала в редакторе Cursor, а с 10 июля 2026 года в Claude Code. Этот документ описывает путь целиком.

Почему это важно как инженерная позиция. Если память и инструменты живут внутри промпта модели, проект умирает вместе с моделью. Если они живут в платформе — модель становится заменяемым компонентом, а накопленное остаётся. Все архитектурные решения ниже — следствие этого выбора.

2. Хронология развития

TIMELINE • HOW THE PROJECT GREW

до 10.07	Начальная архитектура: <code>main.py</code> , <code>models/qwen.py</code> , структура папок
10.07	<code>core/assistant.py</code> + SQLite-память (базовая, по ключевым словам)
10.07	Переход с Cursor на Claude Code — в тот же день, из-за лимита free-плана
10.07 веч.	Извлечение фактов через саму модель + смысловая дедупликация
10.07	Личность: <code>personality/system.md</code>
12.07	Инструменты, базовая версия: три штуки — время, список файлов, чтение файла
12.07	Расширение до шести (<code>write_file</code> , <code>search_files</code> , <code>recall_memory</code>), создан <code>CLAUDE.md</code>
13.07	Планировщик: задачи и напоминания
13.07	Исходный план закрыт полностью — веха
18.07	Обслуживание: удалена старая копия <code>~/main.py</code> (v0.2), версия <code>v0.4</code> → <code>v1.0</code>
23.07	Веб-интерфейс v1: FastAPI + SSE, тёмная/светлая тема, анимации
25.07	Веб расширен: интерактив + <code>web_search</code> как десятый инструмент
25.07	Запуск одной иконкой: <code>~/Applications/TrifonAI.app</code>
25.07	Подтверждение записи файлов в веб-версии — починено

Глава 1. Начальная архитектура до 10.07.2026

Первая версия — Python и Ollama, и сразу с принципом, который дальше определил всё: **один файл = одна ответственность**. Не «скрипт, который со временем обрастёт», а модульная структура с самого начала: `main.py` как тонкий UI-цикл, `models/qwen.py` как единственное место, знающее про Ollama, отдельные папки под память, инструменты и личность.

Именно это решение позже сделало возможным всё остальное. Когда появился веб-интерфейс, терминальный `main.py` не пришлось переписывать — он остался одним из двух клиентов к одному и тому же ядру. Когда понадобилось искать бинарник Ollama в разных местах системы, менялся один файл.

Глава 2. Память 10.07.2026

Память в TrifonAI живёт в SQLite (`memory/trifonai.db`) и состоит из двух разных сущностей: **история диалогов** — что говорилось, и **факты** — что из этого стоит помнить всегда.

Развитие механизма извлечения фактов шло тремя шагами, и каждый следующий появлялся потому, что предыдущий упирался в потолок:

1. **Ключевые слова.** Простое правило: если в сообщении встречается «меня зовут», «я работаю», «мне нравится» — сохранить как факт. Работало, но ловило единицы процентов и не понимало перефразировок.
2. **Извлечение через модель.** Тот же движок, который отвечает пользователю, отдельным вызовом решает: есть ли в этом сообщении факт, который стоит запомнить, и как его сформулировать. Качество выросло резко.
3. **Смысловая дедупликация.** Немедленно вылезла новая проблема: «я живу в Москве» и «мой город — Москва» — это один факт в двух формулировках, и строковое сравнение их не поймает. Решение — снова модель: перед сохранением она сравнивает новый факт с уже имеющимися по смыслу и решает, создавать запись или обновлять существующую.

Это, пожалуй, самое концептуальное решение проекта: модель используется не только как собеседник, но и как инструмент внутри платформы — как семантический компаратор, у которого нет альтернативы в детерминированном коде.

Глава 3. Смена инструмента разработки 10.07.2026

Разработка шла в Cursor, пока не закончились лимиты бесплатного плана — в тот же день, 10 июля, произошёл переход на Claude Code, который дальше стал основным инструментом. Вместе с этим 12 июля появился `CLAUDE.md` — контекстный файл проекта, чтобы ассистент разработки при каждом запуске знал архитектуру, принципы и текущее состояние, а не восстанавливал их из переписки.

Глава 4. Личность 10.07.2026

`personality/system.md` — отдельный файл, а не строка в коде. В нём идентичность (кто такой Трифон), характер, стиль общения и правила работы с памятью: когда обращаться к фактам, как их упоминать, чего не делать. Личность лежит рядом с кодом как редактируемый текст — её можно править, не касаясь логики, и она переживает смену модели.

Глава 5. Инструменты 12.07.2026 → 25.07.2026

Момент, когда ассистент перестал быть говорящей головой. Началось с трёх простых инструментов — текущее время, список файлов, чтение файла — и `tools/registry.py` как реестра с протоколом вызова. В тот же день набор дошёл до шести: запись файлов, поиск по файлам, доступ к собственной памяти.

Ключевое решение здесь — **запись файлов только с обязательным подтверждением человека**. Ассистент, который может писать на диск без спроса, — это не удобство, а риск, и подтверждение было заложено сразу, а не добавлено после инцидента. Позже именно это требование обернулось самой сложной инженерной задачей проекта (см. §3.6).

К 25 июля инструментов стало десять — с задачами и веб-поиском. Инструмент `get_current_time` по ходу был удалён: время оказалось правильнее подавать в контекст всегда, а не заставлять модель запрашивать его вызовом.

Глава 6. Планировщик 13.07.2026

Задачи и напоминания: `tools/tasks.py` для управления, таблица `tasks` в базе, `core/reminders.py` для показа актуальных напоминаний при старте. Простая с виду функция, породившая несколько раундов багов вокруг арифметики относительных дат — «завтра», «послезавтра». Подробности в §3.3.

MILESTONE • 13.07.2026

Исходный план закрыт полностью. Всё, что задумывалось в начале — локальная модель, долговременная память, личность, агентские инструменты, планировщик, — работало. Проект дошёл до состояния, в котором его можно было просто использовать. Всё дальнейшее — уже не выполнение плана, а его продолжение по собственной воле.

Глава 7. Обслуживание 18.07.2026

Небольшая, но показательная дата. Удалена старая копия `~/main.py (v0.2)`, болтавшаяся в домашней папке и способная однажды запуститься вместо настоящей версии. Версия переименована из `v0.4` в `v1.0` — не косметика, а признание, что проект вышел из состояния черновика. Единый источник версии живёт в `core/version.py`, чтобы номер не расползался по файлам.

Глава 8. Веб-интерфейс 23.07 → 25.07.2026

Переход от терминала к браузеру: FastAPI-сервер (`ui/server.py`) и весь фронтенд одним файлом (`ui/static/index.html`) — тот же принцип минимальной структуры, что и в ядре.

Самое интересное здесь — **SSE-поток событий в реальном времени**. Веб-версия не просто показывает финальный ответ: видно, как ассистент думает. Вызов инструмента — событие. Момент срабатывания памяти — событие. Всё это приходит в браузер потоком и отображается вживую, а технические детали можно развернуть, если интересно, и свернуть, если нет. Плюс тёмная и светлая тема, аккуратные анимации и markdown-рендеринг ответов.

25 июля веб-версия получила интерактив и десятый инструмент — `web_search` через пакет `ddgs` (DuckDuckGo). Первое и единственное осознанное исключение из правила «ничего наружу».

Глава 9. Запуск одной иконкой 25.07.2026

Скрипты `scripts/start_web.sh`, `stop_web.sh` и `build_app.sh` превратили проект из «зайти в терминал, активировать окружение, запустить» в `~/Applications/TrifonAI.app` — полноценное macOS-приложение в Dock и Launchpad. Психологически это самый большой сдвиг во всём проекте: то, что запускается иконкой, перестаёт быть экспериментом и становится программой, которой пользуешься. Именно здесь вылезла грабля с macOS TCC (§3.5).

3. Технические трудности

ENGINEERING WAR STORIES • BUGS AND ROOT CAUSES

Самая содержательная часть пути. Здесь собраны баги, где путь от симптома до причины был очевиден, а правильное решение требовало понимания настоящей причины, а не косметического патча.

3.1 ANSI escape-коды Ollama в сохранённом тексте

СИМПТОМ	В базе и в интерфейсе в тексте ответов попадался мусор — обрывки вроде управляющих последовательностей вокруг нормальных слов.
ГИПОТЕЗА	Проблема кодировки или битый вывод модели.
ПРИЧИНА	Ollama в CLI-режиме подмешивает в поток ANSI escape-коды — для терминала это управление курсором и цветом, для программы, читающей вывод, — часть строки. В терминале мусор был невидим, потому что терминал его исполнял, а не печатал. В базу он попадал как есть.
РЕШЕНИЕ	Отдельный слой очистки — <code>core/text.py</code> , функция <code>clean_model_output()</code> . Не патч в месте сохранения, а единая точка: всё, что приходит от модели, проходит через неё.

3.2 SQLite LOWER() и кириллица

СИМПТОМ	Поиск по памяти находил не всё: запрос «москва» не находил факт со словом «Москва».
ГИПОТЕЗА	Ошибка в SQL-запросе или в формировании условий поиска.
ПРИЧИНА	Встроенный LOWER() в SQLite по умолчанию работает только с ASCII — кириллические буквы он не приводит к нижнему регистру и оставляет как есть. SQL был корректен; неверным было предположение о его семантике.
РЕШЕНИЕ	Приведение регистра перенесено в Python, где Unicode работает как ожидается, — на стороне запроса, а не движка базы.

3.3 Арифметика относительных дат

СИМПТОМ	«Напомни послезавтра» ставило напоминание на +3 дня вместо +2. Похожие сдвиги вылезали и на «завтра».
ГИПОТЕЗА	Модель неправильно понимает слово.
ПРИЧИНА	Двойной сдвиг: смещение прибавлялось и при разборе фразы, и при сохранении задачи. Плюс путаница в точке отсчёта — «от сегодня» против «от завтра». Баг возвращался несколько раз в разных формах, потому что каждый раз правился симптом в одном из двух мест.
РЕШЕНИЕ	Единственная точка, где относительная дата превращается в абсолютную, и явная передача текущей даты в контекст. Урок: относительное время нельзя пересчитывать более одного раза за путь запроса.

3.4 `clean_model_output()` съедал переносы строк в списках

СИМПТОМ	В веб-версии списки склеивались в один абзац: пункты шли подряд без переносов.
ГИПОТЕЗА	Баг в markdown-рендеринге фронтенда — ведь в терминале всё было нормально.
ПРИЧИНА	Ollama ставит два пробела в конце строки; эвристика в <code>clean_model_output()</code> принимала это за артефакт разрыва стриминга и убирала перенос. Важная деталь: баг был общий — он бил и терминал, и веб, но проявился только в вебе, потому что markdown-рендеринг требует переносов, а терминальный вывод к ним снисходителен.
РЕШЕНИЕ	Эвристика уточнена: два пробела в конце строки перестали считаться признаком разрыва. Правка в ядре, а не во фронтенде — и терминальная версия тоже стала корректнее.

3.5 macOS TCC: разрешения привязаны к подписи процесса

СИМПТОМ	После сборки <code>.app</code> инструменты работы с файлами перестали видеть содержимое папок, хотя «Полный доступ к диску» в системных настройках был выдан.
ГИПОТЕЗА	Разрешение выдано не тому объекту — надо указать другую папку или переоткрыть настройки.
ПРИЧИНА	Системная особенность macOS TCC: разрешения привязываются к подписи процесса , а не к папке <code>.app</code> и не к пути. Приложение-обёртка, запускающее скрипт, и сам процесс интерпретатора — с точки зрения TCC разные субъекты. Разрешение было выдано не тому, кто на самом деле обращался к диску.
РЕШЕНИЕ	Разбираться с моделью безопасности системы, а не с кодом: понять, какой именно процесс TCC видит как субъект доступа, и выдавать право ему. Ни одной строкой Python это не лечилось.

3.6 `input()` не существует в браузере

- СИМПТОМ** Подтверждение записи файлов, работавшее в терминале, в веб-версии не работало вообще.
- ПРИЧИНА** Не баг, а архитектурное несоответствие. В терминале подтверждение — это `input()`: синхронная блокировка потока до ответа человека. В веб-запросе блокировать поток нельзя, а ответ придёт отдельным HTTP-запросом позже — возможно, из другого соединения.
- РЕШЕНИЕ** Полностью новый механизм: `core/confirm.py` как абстракция подтверждения с двумя реализациями. Запрос на запись получает **токен**, уходит в браузер SSE-событием, ждёт подтверждения на `/api/writes/{token}/confirm` и только тогда выполняется. Терминальная версия продолжила работать через `input()` — за той же абстракцией.

3.7 `threading.local` в многопоточном пуле Starlette

- СИМПТОМ** События терялись: часть вызовов инструментов и срабатываний памяти не доходила до браузера. Непредсказуемо — то доходили, то нет.
- ГИПОТЕЗА** Проблема на стороне SSE — обрыв соединения, буферизация, потеря в сети.
- ПРИЧИНА** Канал событий хранился в `threading.local`. Starlette выполняет синхронный код в пуле потоков, поэтому части одного запроса выполнялись в разных потоках — и код, публикующий событие, видел пустое локальное хранилище вместо канала. Событие уходило в никуда. Плавающий характер бага — прямое следствие того, какой поток из пула достался.
- РЕШЕНИЕ** Отказ от привязки контекста к потоку — контекст события передаётся явно, по границе запроса, а не через поток. Самая тонкая находка проекта: симптом указывал на транспорт, причина была в модели исполнения фреймворка.

3.8 Кеш браузера, который выглядел как баг

- СИМПТОМ** Правка внесена, сервер перезапущен — поведение старое. Похоже, что исправление не работает.
- ПРИЧИНА** Браузер отдавал закешированный `index.html`. Код был правильный с самого начала.
- РЕШЕНИЕ** Жёсткая перезагрузка — и вывод на будущее: прежде чем искать баг в логике, убедиться, что запущен именно тот код, который правился. Полдня диагностики может уйти на проблему, которой нет.

Сводка багов

БАГ	НАСТОЯЩАЯ ПРИЧИНА	РЕШЕНИЕ
Мусор в сохранённом тексте	ANSI escape-коды в CLI-выводе Ollama; терминал их исполнял, база — сохраняла	Единая точка очистки: <code>clean_model_output()</code>
Поиск по памяти пропускал факты	SQLite LOWER() не работает с кириллицей (ASCII-only)	Регистр приводится в Python, а не в SQL
«Послезавтра» = +3 дня	Двойное применение сдвига и расхождение точки отсчёта	Одна точка перевода в абсолютную дату; дата в контексте
Списки склеивались в абзац	Два пробела Ollama в конце строки принимались за разрыв стриминга	Уточнена эвристика в ядре — исправило и терминал, и веб
Нет доступа к диску у .app	macOS TCC привязывает права к подписи процесса, а не к папке .app	Право выдано реальному субъекту доступа, а не обёртке
Подтверждение записи не работало в вебе	Блокирующий <code>input()</code> физически невозможен в HTTP-запросе	Токены + SSE + отдельный эндпоинт подтверждения за общей абстракцией
События терялись по пути в браузер	<code>threading.local</code> в пуле потоков Starlette: разные потоки одного запроса	Контекст события передаётся явно, не через поток
Правка «не применялась»	Кеш браузера отдавал старый <code>index.html</code> ; бага не было	Жёсткая перезагрузка; сначала проверять, что запущен нужный код

4. Архитектура сегодня

ARCHITECTURE · V1.2




Рис. 1 — Слои платформы. Клиенты взаимозаменяемы; ядро одно.

Карта файлов

ПУТЬ	ОТВЕТСТВЕННОСТЬ
main.py	Терминальная версия — тонкий UI-цикл
core/assistant.py	Класс Assistant: оркестрация модели, памяти и инструментов
core/text.py	clean_model_output() — чистка ANSI-кодов Ollama
core/memory_evaluator.py	Извлечение фактов и смысловая дедупликация через модель
core/reminders.py	Показ актуальных напоминаний при старте
core/confirm.py	Абстракция подтверждения записи: терминал и веб
core/version.py	Единый источник версии (v1.2)
memory/database.py	SQLite: таблицы conversations, facts, tasks
models/qwen.py	Вызов Ollama; поиск бинарника по PATH с фолбэками
tools/registry.py	Реестр инструментов и протокол вызова
personality/system.md	Характер, идентичность, правила работы с памятью
ui/static/index.html	Весь веб-фронтенд одним файлом
scripts/*.sh	Запуск и остановка веб-версии, сборка .app
CLAUDE.md	Контекст проекта для Claude Code

Десять инструментов

ИНСТРУМЕНТ	МОДУЛЬ	ЧТО ДЕЛАЕТ
list_files	tools/basic.py	Содержимое папки
read_file	tools/basic.py	Чтение файла
write_file	tools/basic.py	Запись файла — только после подтверждения человеком
search_files	tools/basic.py	Поиск по файлам
recall_memory	tools/basic.py	Доступ к собственной памяти — фактам и истории
add_task	tools/tasks.py	Новая задача или напоминание
list_tasks	tools/tasks.py	Список активных задач
complete_task	tools/tasks.py	Заккрыть задачу
complete_all_tasks	tools/tasks.py	Батч-закрытие — обход слабости модели в длинных цепочках вызовов
web_search	tools/web.py	Поиск в интернете через ddgs (DuckDuckGo)

get_current_time был одиннадцатым и удалён осознанно: текущее время подаётся в контекст всегда, отдельный вызов оказался лишним звеном и источником ошибок в датах.

Как работает память

1

Пользователь пишет сообщение → Assistant сохраняет реплику в conversations

2

memory_evaluator отдельным вызовом спрашивает модель: есть ли здесь факт, который стоит помнить?

3

Факт есть → из facts достаются похожие записи

4

Второй вызов модели — сравнение по смыслу, а не по строке: дубликат или новое?

5

Новое → INSERT; дубликат с новой формулировкой → UPDATE существующей записи

6

В веб-версии каждый шаг уходит в браузер SSE-событием — видно, как память срабатывает

Рис. 2 — Путь факта: извлечение → проверка дубликата → сохранение или обновление.

Путь сообщения в веб-версии



Рис. 3 — Поток одного сообщения через веб-версию.

5. Ограничения и компромиссы

KNOWN LIMITATIONS • HONESTLY

- **Маленькая модель не всегда держит стиль.** `qwen3:8b` периодически нарушает инструкции из `system.md` — вставляет эмодзи там, где не надо, или уходит в многословность. Цена локальности.
- **Не тянет длинные цепочки однотипных вызовов.** Десять последовательных вызовов одного инструмента модель не доводит до конца. Решение не в промпте, а в архитектуре: батч-инструменты вместо чейнинга — отсюда `complete_all_tasks`.
- **Нет мультимодальности.** Ассистент не видит изображения — только текст.
- **Несколько моделей одновременно — осознанно отложено.** Архитектура к этому готова (модель отделена в `models/`), но задача не решает текущей боли и ждёт.

6. Что дальше

NEXT • TOWARD A WEAK LOCAL CLAUDE CODE

Цель следующего этапа сформулирована прямо: превратить TrifonAI в «слабую версию Claude Code» — локального агента, который не только читает и пишет файлы, но и работает с проектом по-настоящему. Три направления:

- **Выполнение команд в терминале** — с тем же принципом обязательного подтверждения, что уже отработан на записи файлов.
- **Точечное редактирование файлов** вместо перезаписи целиком — правка фрагмента, а не файла.

- **Более длинный агентский цикл** — способность держать многошаговую задачу, а не один вызов инструмента за ход. Здесь ограничение модели (см. §5) станет главным препятствием, и, вероятно, именно оно определит, когда придёт время для сменного движка помощнее.

Что важно: платформа к этому готова архитектурно. Реестр инструментов расширяется одним файлом, подтверждение уже абстрагировано под два интерфейса, память и личность от модели не зависят. Именно это и было целью с самого начала — и, пожалуй, главный результат двух недель работы: не набор функций, а фундамент, на котором следующий шаг не требует переписывания.