

Память Claude

Как агент помнит ваш проект между сессиями. И почему именно здесь у людей тихо ломаются агенты.

WARNING: MEMORY.md is 208 lines and 52.9KB. Only part of it was loaded.

— Один warning, объясняющий половину «тупняков»

Каждая новая сессия Claude стартует с чистого окна контекста. Модель не помнит вчерашний разговор. Чтобы знание не обнулялось, есть память. Но память это не одна штука, а две, и именно поэтому их постоянно путают, а на стыке тихо теряют данные.

Я наткнулся на разрыв вживую. В начало сессии мне в контекст приехала та самая служебная строка с обложки. Перевод на человеческий: «твой индекс памяти разросся, я загрузил не весь». Звучит как мелочь. На деле это объяснение целого класса ошибок, который выглядит как «агент тупит, забыл то, что я говорил». Он не забыл. Он не увидел.

— Два механизма, которые все путают

В Claude Code память это две системы. Обе грузятся в начале каждой сессии. Обе для модели **контекст, а не приказ** (к этому вернёмся).

СВЕРХУ ВНИЗ

CLAUDE.md

Кто пишет: вы

Что внутри: инструкции, правила, стандарты, архитектура

Гружится: каждую сессию, целиком

Пример: «используй `pnpm`, а не `npm`»

АГЕНТ САМ

Auto memory

Кто пишет: сам Claude

Что внутри: выученные факты, build-команды, ваши привычки

Гружится: первые 200 строк или 25KB

Пример: «`build` тут `pnpm build`, проверено»

Ментальная модель: CLAUDE.md это ваши инструкции агенту. Auto memory это записная книжка агента про вас. Первое идёт от вас к модели. Второе модель набивает себе сама, решая по ходу, что пригодится потом.

— Как устроена auto memory под капотом

Работает у всех по умолчанию (нужна версия Claude Code 2.1.59 или новее). У каждого проекта своя папка памяти, привязанная к корню git-репозитория. Внутри файл-индекс `MEMORY.md` и сколько угодно topic-файлов, которые агент создаёт сам:

```
memory/
├─ MEMORY.md ← индекс, грузится в каждую сессию
├─ debugging.md ← детали по отладке
├─ api-conventions.md ← решения по API
└─ ... ← любые topic-файлы Claude создаёт сам
```

Ключевой нюанс загрузки

ЧТО ГРУЗИТСЯ	СКОЛЬКО
<code>MEMORY.md</code> (индекс)	первые 200 строк ИЛИ 25KB , что наступит раньше. Дальше на старте не грузится
<code>CLAUDE.md</code>	целиком, независимо от длины
topic-файлы (debugging.md и пр.)	на старте не грузятся, агент читает по требованию

Архитектурный замысел: **MEMORY.md это тонкий указатель, а не склад**. Детали выносятся в topic-файлы, индекс остаётся компактным. Это не для аккуратистов, это условие работы: что не влезло в порог, того для агента на старте не существует.

НЕОЧЕВИДНАЯ СВЯЗЬ

— Где это тихо ломается

Вернёмся к warning. Мой индекс был 208 строк и 52.9KB. Порог: 200 строк или 25KB, что раньше. 52.9KB вдвое больше 25KB, значит обрезка случилась по объёму, примерно на половине файла. Грубо: **половину собственной памяти агент на старте не видел**.

Вы поправили агента → он честно записал в MEMORY.md → индекс со временем распух → нужная строка ушла за 25KB-порог → агент стартует без неё → спокойно повторяет старую ошибку. Он не врёт и не саботирует. Он физически не получил эту строку в контекст.

Это переворачивает диагностику. Когда агент «забыл» выученное, первый вопрос не «почему ты тупой», а **«эта запись вообще попала в загружаемую часть индекса?»**. Чаще всего проблема не в модели, а в раздутом нерасслоённом индексе.

Вторая ловушка: своя память молчит

Продвинутые пользователи (и я в этой системе) ведут **свою ручную папку памяти** параллельно платформенной: чистый каталог с профилями, проектами, выверенными

принципами. Он лучше служебного. Но **по умолчанию платформа автоматически инжектит только своё MEMORY.md**, а ваш ручной каталог на старте не подтягивает, если вы его явно не подключили.

И тут же решение. «Не подтягивает» верно лишь пока вы не провели каталог в загрузку сами. CLAUDE.md грузится целиком (без лимита 200/25KB) и поддерживает **@import**: по доке импортированные файлы разворачиваются и грузятся в контекст на старте. Пропишите `@путь/к/каталогу` в CLAUDE.md или вынесите инструкции в `.claude/rules/`, и ручной каталог будет подхватываться автоматически каждую сессию.

Парадокс по умолчанию: худшая, обрезанная половина платформенного индекса грузится всегда и автоматически. Лучший вылизанный каталог молчит, пока вы не подключите его явно. Два хранилища живут параллельно и не знают друг о друге, пока вы их не свяжете. Стык между ними и есть корень большинства «провалов памяти».

— Гвоздь: память это контекст, а не закон

Ни CLAUDE.md, ни auto memory не являются жёсткой конфигурацией. Официально модель трактует их как контекст, а не принудительную настройку. Более того, CLAUDE.md технически доставляется как сообщение пользователя после системного промта. Модель читает и старается следовать, но гарантии строгого исполнения нет, особенно для размытых или противоречивых инструкций.

Практический вывод. То, что должно срабатывать всегда и безусловно (запретить команду, прогнать линтер перед коммитом, заблокировать путь), пишется не в память, а в **hook** (PreToolUse и подобные). Hook это shell-команда на фиксированном событии, она выполняется независимо от решения модели. Память влияет на поведение. Hook его обеспечивает. Путать эти уровни дорого.

ДЕЙСТВИЕ

— Что с этим делать

1. **Держите MEMORY.md под порогом.** Перевалил за 200 строк / 25KB, часть памяти уже не работает. Расслоите: указатели в индексе, контент в topic-файлах.
2. **Проверяйте, что грузится,** командой `/memory`. Нет файла в списке, агент его не видит.
3. **Подключите свой каталог явно.** По умолчанию автоматически грузится только служебный MEMORY.md. Хотите, чтобы ручной каталог тянулся сам, пропишите

`@import` в CLAUDE.md или вынесите в `.claude/rules/` (грузится на старте целиком, без лимита).

4. **Срочное и безусловное выносите в hooks**, а не в память.
5. **Пишите конкретно и коротко.** Проверяемые формулировки слушаются надёжнее расплывчатых.
6. **Чистите периодически.** Противоречивые записи модель разрешает произвольно, то есть может выбрать неверную.

— Где этот разбор может быть неполон

Cowork отличается от ванильного Claude Code. Базовый механизм auto memory описан по официальной доке Claude Code. Cowork построен поверх, но хранит память в своём служебном пути и использует слегка свой формат записей (frontmatter с типами и связями через двойные скобки). Механизм тот же, обёртка другая.

Цифры могут сдвинуться. Порог 200 строк / 25KB и версия 2.1.59 актуальны на июнь 2026. Это продуктовые параметры, проверяйте по текущей доке.

«Половина памяти не грузится» это про конкретный распухший файл, а не общий закон. При аккуратном индексе на 80 строк обрезки нет вовсе.

Калибровка. Механика двух систем, лимит загрузки, разделение «контекст vs hook»: подтверждено офдокой, уверенность высокая. Тезис «стык двух хранилищ = корень большинства провалов памяти»: обобщение из наблюдаемого паттерна, а не замеренная статистика, уверенность средняя.

Источники:

How Claude remembers your project, Claude Code Docs: docs.claude.com/en/docs/claude-code/memory

Memory tool (отдельная API-фича, не путать с auto memory): docs.claude.com/en/docs/agents-and-tools/tool-use/memory-tool

GORILLA UNDER HOOD

Разбираю, как AI-агенты устроены внутри

Механика под капотом, рабочие сетапы и грабли, на которые натыкаешься вживую. Без инфоцыганства, на своих кейсах.



Наведи камеру → подпишись

@gorilla_under_hood

t.me/gorilla_under_hood