

# Супер-интеллект ансамбль для поиска

## OpenRouter Fusion MCP для Codex

### Что это?

Представь, что у тебя есть вопрос, где ошибка стоит дорого: стратегия, продукт, рынок, архитектура, исследование, юридический риск, важная покупка, спорная гипотеза. Обычный чат с ИИ может ответить быстро и уверенно, но уверенность не равна правде.

**Решение:** консенсус моделей. Вместо того чтобы доверять одному ответу одной модели, ты запускаешь совет из нескольких ИИ-экспертов. Они независимо разбирают задачу, спорят с идеей с разных сторон, подсвечивают риски и помогают получить более сильный итоговый вывод.

Это рабочий способ получить второй, третий и пятый взгляд на сложный вопрос за один запуск.

**Суть:** локальный MCP-сервер добавляет в Codex инструмент `fusion`. Когда ты просишь Codex запустить Fusion, запрос отправляется в OpenRouter. Несколько моделей анализируют задачу параллельно, а модель-судья собирает результат: консенсус, противоречия, частичное покрытие, уникальные идеи, слепые пятна и финальный ответ.

Fusion особенно полезен, когда тебе нужен не просто "ответ", а проверенная позиция: что вероятнее, где риски, в чём модели не согласны и что стоит перепроверить вручную.

### Для кого

- **Маркетинг:** проверить оффер, сегмент, УТП, позиционирование, креативы, лендинг, рекламную гипотезу.  
Пример: Запусти `fusion` и разбери, почему этот оффер для B2B SaaS может не конвертить. Дай 5 гипотез, риски и варианты тестов.
- **Бизнес и стратегия:** сравнить варианты выхода на рынок, найти слабые места в стратегии, оценить конкурентов, подготовиться к переговорам.  
Пример: Запусти `fusion` и сравни 3 стратегии монетизации для моего продукта: подписка, `usage-based` и `enterprise deals`.
- **Основатели и руководители:** принять решение, где важно увидеть не только плюсы, но и скрытые риски.  
Пример: Запусти `fusion` и выступи как совет директоров: стоит ли нам делать `pivot` в сторону `enterprise-клиентов`?
- **Продукт и UX:** оценить фичу, CJM, onboarding, механику удержания, `pricing page` или пользовательский сценарий.  
Пример: Запусти `fusion` и найди слабые места в `onboarding` для нового пользователя. Дай рекомендации по приоритетам.

- **Разработка и архитектура:** сравнить технические подходы, найти edge cases, риски миграции, слабые места в API/биллинге/инфраструктуре.  
Пример: Запусти fusion и сравни варианты хранения истории чатов: SQLite, Postgres и event log. Дай рекомендацию для MVP и для роста.
- **Исследования, аналитика и R&D:** собрать несколько независимых рассуждений, найти противоречия, сформулировать план проверки.  
Пример: Запусти fusion и составь карту аргументов за и против этой научной гипотезы. Отдельно укажи, что нужно проверять источниками.
- **Обучение и разбор сложных тем:** получить объяснение с разных сторон и увидеть, где есть спорные места.  
Пример: Запусти fusion и объясни reinforcement learning с нуля, но отдельно покажи разные интуиции и типичные ошибки новичков.
- **Личные решения с высокой ценой ошибки:** сравнить варианты покупки, обучения, переезда, выбора подрядчика или инструмента.  
Пример: Запусти fusion и помоги выбрать между двумя ноутбуками для разработки и локальных моделей. Сравни по рискам, цене и сроку службы.

Важно: консенсус моделей не гарантирует истину. Он снижает риск одиночной ошибки и помогает увидеть больше углов, но факты, цифры, законы, медицину, финансы и критичные решения всё равно нужно проверять по источникам.

## Пример состава моделей

Например, можно собрать консенсус из нескольких моделей:

```
moonshotai/kimi-k2.7-code
qwen/qwen3.7-plus
minimax/minimax-m3
qwen/qwen3.7-max
x-ai/grok-4.3
```

А моделью-судьёй поставить:

```
deepseek/deepseek-v4-pro
```

Такой ансамбль часто даёт более устойчивый и разносторонний анализ, чем одиночная модель: одна модель сильнее в коде, другая в рассуждении, третья лучше видит продуктовые риски, четвёртая жёстче критикует. На выходе ты получаешь не один голос, а сводку нескольких позиций.

Но качество зависит от доступности моделей в OpenRouter, формулировки запроса, лимитов, стоимости и текущего состояния провайдеров.

## Что понадобится

1. Установленный Codex CLI.
2. Файл локального MCP-сервера:

```
tools/openrouter_fusion_mcp.py
```

3. Аккаунт OpenRouter:

```
https://openrouter.ai
```

4. API-ключ OpenRouter:

```
https://openrouter.ai/workspaces/default/keys
```

5. Файл конфигурации Codex:

```
~/.codex/config.toml
```

## Как это работает

После настройки Codex запускает локальный Python-файл как MCP-сервер:

```
/opt/homebrew/bin/python3  
/Users/artem/Desktop/chatbot/tools/openrouter_fusion_mcp.py (пути показаны как  
пример!)
```

Дальше происходит так:

```
Codex  
-> запускает локальный MCP server  
-> спрашивает список tools  
-> видит tool fusion  
-> вызывает fusion с твоим вопросом  
-> MCP server отправляет запрос в OpenRouter  
-> OpenRouter запускает openrouter:fusion  
-> ответ возвращается обратно в Codex
```

Файл `openrouter_fusion_mcp.py` не является обычной CLI-программой. Если просто запустить его руками, он будет молчать, потому что ждёт MCP/JSON-RPC сообщения через `stdin`.

## Установка

### 1. Положи файл в проект

В корне проекта должна быть папка `tools`:

```
tools/openrouter_fusion_mcp.py
```

Если папки нет:

```
mkdir -p tools
```

Скопируй файл `openrouter_fusion_mcp.py` внутрь этой папки.

## 2. Узнай путь к Python

В терминале:

```
which python3
```

На Mac с Homebrew часто будет:

```
/opt/homebrew/bin/python3
```

На других системах путь может быть другим, например:

```
/usr/bin/python3
```

В config нужно вставлять именно свой путь.

## 3. Узнай абсолютный путь к проекту

Перейди в проект и выполни:

```
pwd
```

Пример:

```
/Users/artem/Desktop/chatbot
```

Тогда путь к MCP-файлу будет:

```
/Users/artem/Desktop/chatbot/tools/openrouter_fusion_mcp.py
```

## Настройка config.toml

Открой глобальный config Codex:

```
nano ~/.codex/config.toml
```

`sudo` обычно не нужен. Если файл не открывается из-за прав, сначала проверь, что ты редактируешь именно свой `~/ .codex/config.toml`.

В конец файла добавь блок:

```
[mcp_servers.openrouter_fusion]
command = "/opt/homebrew/bin/python3"
args = ["/Users/artem/Desktop/chatbot/tools/openrouter_fusion_mcp.py"]
cwd = "/Users/artem/Desktop/chatbot"
startup_timeout_sec = 30
tool_timeout_sec = 400
enabled_tools = ["fusion"]
default_tools_approval_mode = "prompt"

[mcp_servers.openrouter_fusion.env]
OPENROUTER_API_KEY = "sk-or-v1-..."
```

Что заменить:

- `command` — путь из команды `which python3`.
- `args` — абсолютный путь к `tools/openrouter_fusion_mcp.py`.
- `cwd` — абсолютный путь к проекту.
- `OPENROUTER_API_KEY` — твой ключ OpenRouter.

Сохранить в `nano` :

```
Ctrl + O
Enter
Ctrl + X
```

Можно открыть файл и любым обычным редактором, если так удобнее.

## Важное про API-ключ

Для первой проверки можно вставить ключ прямо в `config.toml`.

Но если конфиг лежит внутри проекта, не коммить его в `git`. API-ключ нельзя публиковать.

Более безопасный вариант — держать ключ в переменной окружения, но для быстрого старта проще использовать блок:

```
[mcp_servers.openrouter_fusion.env]
OPENROUTER_API_KEY = "sk-or-v1-..."
```

## Перезапусти Codex

После изменения `config.toml` полностью закрой и заново открой Codex CLI.

Codex читает MCP-конфиг на старте. Если не перезапустить Codex, новый инструмент может не появиться.

## Как проверить, что Codex видит MCP server

В терминале:

```
codex mcp list
codex mcp get openrouter_fusion
```

В выводе должно быть примерно:

```
openrouter_fusion
  enabled: true
  transport: stdio
  command: /opt/homebrew/bin/python3
  args: /.../tools/openrouter_fusion_mcp.py
  enabled_tools: fusion
```

Если путь в `args` неправильный, сервер не стартует.

## Как запустить Fusion из Codex

Пиши обычным языком, но явно упоминай `fusion`, чтобы Codex понял, что нужно вызвать MCP-инструмент.

Минимальный запрос:

```
Запусти fusion и сравни подходы к реализации billing в этом проекте.
```

Для бизнес-гипотезы:

```
Запусти fusion и проверь гипотезу: "малому бизнесу нужен AI-ассистент для обработки входящих заявок". Разбери спрос, боли, возражения, конкурентов, каналы продаж и первые тесты.
```

Для маркетинга:

```
Запусти fusion и разбери этот лендинг как performance marketer, продуктовый маркетолог и скептический покупатель. Найди слабые места, предложи новые офферы и A/B тесты.
```

Для разработки:

Запусти fusion и сравни два технических подхода: хранить billing ledger в SQLite append-only файлах или сразу перейти на Postgres. Укажи риски, сложность миграции и рекомендацию для MVP.

Для решения:

Запусти fusion и помоги принять решение: нанимать senior-разработчика сейчас или закрыть задачу подрядчиком. Дай аргументы за/против, риски, условия выбора и итоговую рекомендацию.

С ручным выбором моделей:

Вызови fusion с analysis\_models=["moonshotai/kimi-k2.7-code", "qwen/qwen3.7-max"] и judge\_model="deepseek/deepseek-v4-pro".

Хорошая формула запроса:

Запусти fusion и [что нужно решить].  
Контекст: [кратко кто мы, что делаем, ограничения].  
Нужно получить: [формат ответа].  
Оцени: [риски, альтернативы, стоимость, сроки, спорные места].  
В конце дай: [итоговую рекомендацию и что проверить вручную].

## Что можно просить передавать Codex как доп аргументы

Основные аргументы который поддерживает инструмент :

```
prompt
model
system_prompt
analysis_models
judge_model
max_tool_calls
max_completion_tokens
temperature
reasoning
force
include_raw
```

Минимально нужен только:

prompt – как раз тот вопрос, который мы задаем (его составляет агент)

Остальное можно не указывать: сервер подставит значения по умолчанию.

# Диагностика

Если сервер не стартует, временно добавь в config:

```
[mcp_servers.openrouter_fusion.env]  
OPENROUTER_API_KEY = "sk-or-v1-..."  
OPENROUTER_FUSION_MCP_DEBUG = "1"  
OPENROUTER_FUSION_MCP_LOG = "/private/tmp/openrouter_fusion_mcp.log"
```

После перезапуска Codex проверь лог:

```
sed -n '1,160p' /private/tmp/openrouter_fusion_mcp.log
```

Нормальный старт выглядит так:

```
[openrouter-fusion] server started  
[openrouter-fusion] received method='initialize'  
[openrouter-fusion] received method='notifications/initialized'  
[openrouter-fusion] received method='tools/list'
```

Если ты видишь:

```
[openrouter-fusion] received method='tools/call'  
[openrouter-fusion] calling OpenRouter ...  
[openrouter-fusion] OpenRouter response received status=200
```

значит запрос реально ушёл в OpenRouter и вернулся.

## Частые ошибки

### MCP startup timed out

Что значит: Codex запустил процесс, но не получил нормальный MCP handshake.

Что проверить:

- правильный ли путь в args ;
- существует ли файл tools/openrouter\_fusion\_mcp.py ;
- нет ли синтаксической ошибки в Python-файле;
- перезапустил ли ты Codex после изменения config.

Проверка синтаксиса:

```
python3 -m py_compile tools/openrouter_fusion_mcp.py
```



## connection closed: initialize response

Чаще всего Python-файл упал при старте.

Проверь:

```
python3 -m py_compile tools/openrouter_fusion_mcp.py
```

Если есть синтаксическая ошибка, Codex не сможет запустить MCP-сервер.

## В логе есть только server started

Значит процесс стартовал, но Codex не дошёл до handshake или transport не совпал.

Текущий файл поддерживает:

```
JSONL MCP transport  
Content-Length framing
```

## OpenRouter request failed: nodename nor servname provided

Это DNS/network ошибка. Обычно значит, что среда, где запущен процесс, не имеет доступа к сети.

Проверь интернет, VPN, прокси, sandbox-настройки и доступность `openrouter.ai`.

## Запрос висит слишком долго

Fusion может работать долго, потому что запускает несколько моделей.

Что можно сделать:

- уменьшить `analysis_models`;
- поставить `max_tool_calls = 1`;
- поставить `max_completion_tokens = 512`;
- использовать более быструю outer model;
- увеличить `tool_timeout_sec`, если реально нужен длинный анализ.

## Практические советы

- **Не запускай Fusion на мелочь.** Для вопроса "как назвать переменную" это лишнее. Для стратегии, архитектуры, конкурентов, pricing, рисков, продуктовой гипотезы — самое то.
- **Давай контекст.** Плохой запрос: Оцени идею. Хороший запрос: Оцени идею AI-ассистента для стоматологий в России. ЦА: клиники 3–20 врачей. Цель: понять, стоит ли делать MVP.

- **Проси спор, а не только ответ.** Хорошая формулировка: Покажи, где модели могут не согласиться, какие есть аргументы против и какие факты надо проверить.
- **Проси структуру.** Например: Дай ответ в формате: краткий вывод, аргументы за, аргументы против, риски, что проверить, рекомендация.
- **Ограничивай масштаб.** Если задача большая, проси сначала стратегический анализ, потом отдельным запуском — план действий. Один огромный запрос может быть дороже, медленнее и менее точным.
- **Следи за стоимостью.** Чем больше моделей в `analysis_models`, чем длиннее контекст и чем выше `max_completion_tokens`, тем дороже и дольше запрос.
- **Для быстрых проверок ставь лимиты.** Например: `max_tool_calls=1`, `max_completion_tokens=512`. Для глубокого анализа можно увеличивать.
- **Не доверяй консенсусу слепо.** Если все модели уверенно ошиблись из-за неверного исходного факта, консенсус тоже будет неправильным. Критичные факты проверяй отдельно.
- **Если OpenRouter ругается на модель, замени её.** Иногда конкретная модель временно недоступна у провайдера. Убери её из `analysis_models` или выбери более стабильную.
- **Если запрос висит долго, уменьши состав ансамбля.** Начни с 2-3 моделей, потом расширяй, если ответ реально нужен глубже.
- **Для кода и архитектуры проси edge cases.** Например: Отдельно найди проблемы с миграцией, конкурентным доступом, `idempotency`, `billing` и логированием.
- **Для бизнеса проси go/no-go.** Например: В конце дай решение: делать, не делать или проверить через быстрый тест.