

Claude Managed Agents: платформа для автономных ИИ-агентов

Claude Managed Agents: платформа для агентов ИИ

Ключевые тезисы:




- Эволюция ИИ достигла точки, где инфраструктура стала ключевым ограничением, а не интеллект моделей.
 - Claude Managed Agents — это платформа, которая берет на себя сложности инфраструктуры, безопасности и наблюдаемости, позволяя разработчикам сосредоточиться на создании агентов.
 - Платформа предоставляет готовые примитивы для создания, запуска и наблюдения за автономными агентами.
 - Будущее — за агентами, способными выполнять сложные, долгосрочные задачи (например, сделки M&A) с минимальным вмешательством человека.
-

Эволюция возможностей ИИ

- **Claude 3 / Opus 3:** Возможность выполнять простые, короткие задачи с постоянным контролем (стейкинг) со стороны пользователя.
- **Opus 4 / Claude Code:** Агенты могут вести разработку целых фич и создавать PR, но все еще требуют значительного контроля.
- **Opus 4.7:** Агенты способны самостоятельно закрывать бэклоги и создавать готовые к мержу PR.
- **Будущее:** Выполнение работы за целый квартал за несколько часов с помощью *роя* (swarm) агентских команд.




Мотивация создания платформы

Чтобы агенты могли выполнять сложные задачи, им нужен доступ к большому количеству ресурсов и систем:

-  **Безопасные учетные данные** и доступ к внутренним системам (например, к приватным репозиториям GitHub).
-  **Идентификация и доступ (Identity & Access)** для агентов, как у обычных сотрудников.
-  **Новые парадигмы взаимодействия:**
 - Контекстно-ориентированное (разговорное).
 - **Ориентированное на результат (Outcome-Oriented):** Постановка задачи и ожидание завершения без промежуточного контроля.
 - **Асинхронное:** Возможность запустить агента и вернуться к нему позже (через недели или месяцы).

Проблемы, которые решает платформа

При создании агентов разработчики сталкиваются с ключевыми сложностями:

-  **Управление контекстом и памятью:** Критически важный элемент, ошибки в котором разрушают работу агента.
-  **Инфраструктурные проблемы** (главное препятствие):
 - Надежность, масштабируемость, безопасность.
 - Задержки (latency) при работе в production.
-  **Наблюдаемость (Observability):** Без понимания того, что делает агент и насколько он успешен, невозможно оценить его работу.

Claude Managed Agents берет всю эту платформенную работу на себя, предоставляя готовые, композлируемые примитивы.







Как начать работу: основные примитивы

1. **Определите агента (Define an Agent):** Бандл конфигурации, который задает личность и возможности агента (системный промпт, модель, навыки, инструменты, разрешения).
2. **Создайте среду выполнения (Environment):** "Компьютер" для Клода — песочница (sandbox) с настраиваемым списком сетевого доступа и предустановленными пакетами.
3. **Запустите сессию (Kick off a Session):** Дайте агенту задачу и позвольте ему работать, вернувшись только по завершении.
4. **Наблюдайте через поток событий (Event Stream):** Прослушивайте события в реальном времени, чтобы понимать действия агента.





Поток событий (Event Stream)

Каждая сессия — это лог событий, разделенных на домены для ясности:

-  **Пользовательские события (User Events):** Сообщения, изображения, документы от пользователей, прерывания агента, результаты выполнения кастомных инструментов, подтверждения для "человека в цикле".
-  **События агента (Agent Events):** Ответы Клода, выполнение инструментов, координация с другими агентами.
-  **События сессии (Session Events):** Жизненный цикл сессии (статусы, ошибки, восстановление, обработка результатов).
-  **События интервалов (Span Events):** Отметки начала и окончания длительных операций (например, генерации длинного ответа).



Расширенные функции

-  **Оркестрация нескольких агентов (Multi-Agent Orchestration):** Клод может порождать другие агентские потоки с собственным контекстом для делегирования работы.
-  **Результаты (Outcomes):** Позволяет задать критерии или цели, к которым Клод будет итеративно стремиться, самостоятельно оценивая прогресс.

- 🧠 **Память (Memory):** Долгоживущие хранилища памяти, позволяющие агенту учиться на предыдущих сессиях.
- 🧠 **"Сновидения" (Dreaming, в превью):** Механизм рефлексии и анализа тысяч сессий для создания и улучшения воспоминаний агента.



Новые анонсы

1. 🏠 **Самостоятельно размещаемые песочницы (Self-Hosted Sandboxes):**
 - Возможность использовать свою собственную вычислительную инфраструктуру (в своем VPC).
 - Полный контроль над сетевыми политиками, аудит-логами, жизненным циклом песочниц.
 - Партнеры для быстрого старта: Cloudflare, Daytona, Modal, Vercel.
2. 🚇 **Туннели MCP (MCP Tunnels, в превью):**
 - Безопасное подключение частных MCP-серверов к Claude Managed Agents без необходимости выхода в публичный интернет.
 - Требуется только базовый прокси-слой для установки безопасного туннеля.

Выводы:

Claude Managed Agents — это комплексная платформа, которая снимает с разработчиков тяжесть построения надежной, масштабируемой и безопасной инфраструктуры для ИИ-агентов. Она предоставляет инструменты для создания интеллектуальных помощников, способных автономно выполнять сложные бизнес-задачи, от анализа данных до проведения сделок, при этом обеспечивая полную прозрачность и контроль через развитую систему наблюдаемости.