

Regeneration Credit AI Assistant

Parte II – Desenvolvimento da API REST para Integração
com Frontend

Data: 27/03/2026

Versão: 2.0.0

Relatório Técnico-Executivo

1. Introdução e Contexto

1.1 Recapitulação do Relatório Anterior

O primeiro relatório técnico-executivo (Parte I, v1.0) documentou o desenvolvimento do Regeneration Credit AI Assistant — um chatbot inteligente baseado em RAG (Retrieval-Augmented Generation) capaz de responder dúvidas sobre o projeto Regeneration Credit em linguagem natural e acessível.

Naquela fase, foram entregues os seguintes componentes funcionais:

- Sistema RAG completo com 4 ferramentas especializadas e mais de 120 documentos indexados (contratos Solidity, whitepapers, manuais, documentação técnica)
- Agente inteligente com loop ReAct manual (RegenerationCreditAgent) usando Claude Haiku 4.5 da Anthropic
- Interface Streamlit profissional com abas de Chat, Prompts, Retriever Debug e Tokens & Custos
- Sistema de tracking detalhado de tokens, custos e performance de retrieval
- Memória conversacional e salvamento automático de conversas em JSON enriquecido

O relatório anterior concluiu com um roadmap de três frentes de evolução, entre as quais o item (ii) — Integração com Aplicativo Regeneration Credit — identificava a necessidade de uma API REST como passo fundamental para viabilizar a integração do chatbot com o frontend Next.js do site regenerationcredit.org.

1.2 Objetivo desta Fase

A presente fase materializa a visão descrita no roadmap: o desenvolvimento de uma API REST completa que expõe o chatbot como serviço independente, desacoplado da interface Streamlit. Isso representa a transição da Prova de Conceito (POC) para uma arquitetura de produção, onde backend (agente IA) e frontend (Next.js/React) operam como sistemas independentes conectados via HTTP e WebSocket.

Os objetivos específicos desta entrega são:

- Criar uma API RESTful que exponha todas as funcionalidades do chatbot via endpoints HTTP padronizados
- Implementar gerenciamento de sessões de chat com memória isolada e expiração automática
- Oferecer suporte a WebSocket para experiência de chat em tempo real
- Gerar documentação automática da API (Swagger/OpenAPI) para facilitar integração
- Fornecer exemplos de código prontos para integração com o frontend Next.js

1.3 Escopo deste Relatório

Este documento descreve a arquitetura da API desenvolvida, as decisões técnicas tomadas, os padrões de design adotados, os endpoints disponíveis, o sistema de gerenciamento de sessões e o caminho de integração com o frontend. Complementa a documentação técnica detalhada disponível em `API_README.md` (706 linhas), que inclui exemplos de código e instruções de uso.

2. Motivação e Decisões Arquiteturais

2.1 Por que uma API REST?

A interface Streamlit cumpriu seu papel como ferramenta de prototipagem e validação da POC, mas apresenta limitações significativas para uso em produção:

- **Acoplamento:** A lógica de IA está acoplada à interface — impossível reutilizar o chatbot em outros contextos (mobile, widget embarcado, API pública)
- **Escalabilidade:** Streamlit opera em modelo single-process e não é projetado para atender múltiplos usuários concorrentes em alta escala
- **Flexibilidade de UX:** O frontend Next.js do Regeneration Credit oferece uma experiência de usuário muito mais rica e customizável
- **Padrão da Indústria:** APIs REST são o padrão universal para integração entre sistemas heterogêneos, facilitando colaboração entre equipes

A criação da API REST permite que o mesmo núcleo de IA seja consumido por qualquer cliente — web, mobile, aplicação desktop ou integração com terceiros — sem duplicação de código ou lógica.

2.2 Escolha do FastAPI

O FastAPI foi selecionado como framework para a API após análise de alternativas (Flask, Django REST). Os fatores decisivos foram:

- **Alta Performance:** Framework async nativo construído sobre Starlette e Uvicorn, com performance comparável a Node.js e Go em benchmarks
- **Documentação Automática:** Gera automaticamente Swagger UI e ReDoc a partir dos type hints e modelos Pydantic, eliminando necessidade de documentação manual
- **Validação Nativa:** Integração profunda com Pydantic para validação automática de request/response com type safety completo
- **WebSocket Nativo:** Suporte a WebSocket integrado ao framework, sem dependências adicionais
- **Compatibilidade com o Stack:** Python nativo, integração natural com LangChain, ChromaDB e todo o ecossistema existente

2.3 Padrão de Concorrência

Um desafio técnico central foi conciliar o modelo assíncrono do FastAPI com a natureza síncrona do agente LangChain (que realiza chamadas bloqueantes ao LLM da Anthropic). A solução adotada utiliza `asyncio.to_thread()`:


```
# Dentro do endpoint /chat
result = await asyncio.to_thread(agent.chat, body.message)
```

Essa abordagem delega cada chamada do agente a uma thread separada do pool de threads do Python, liberando o event loop do FastAPI para continuar atendendo outras requisições. O resultado é concorrência efetiva: múltiplas sessões de chat podem ser processadas simultaneamente sem bloquear o servidor.

3. Arquitetura da API

3.1 Visão Geral

A API opera como camada intermediária entre o frontend e o núcleo de IA, traduzindo requisições HTTP/WebSocket em chamadas ao agente e retornando respostas estruturadas em JSON:



3.2 Estrutura de Módulos

A API segue uma organização modular inspirada em padrões de arquitetura limpa, com separação clara entre rotas (controllers), serviços (business logic), modelos (schemas) e middleware:

```
api/
+-- __init__.py
+-- main.py                                # App FastAPI, CORS, lifespan, routers
+-- models/
|   +-- __init__.py
|   +-- schemas.py                        # Schemas Pydantic (request/response)
+-- routers/
|   +-- __init__.py
|   +-- health.py                        # GET /health
|   +-- sessions.py                      # POST/GET/DELETE /sessions
|   +-- chat.py                          # POST /chat + WS /ws/chat
+-- services/
|   +-- __init__.py
|   +-- agent_manager.py                  # Pool de sessoes, TTL, thread-safety
+-- middleware/
|   +-- __init__.py                      # (reservado para rate limiting futuro)
run_api.py                               # Script de inicializacao com argparse
```

Justificativa da organização:

- **Routers:** Cada arquivo define endpoints de um domínio específico (health, sessions, chat), facilitando localização e manutenção
- **Services:** Lógica de negócio isolada (AgentManager) pode ser testada independentemente dos endpoints HTTP
- **Models:** Schemas Pydantic centralizados garantem consistência e são usados tanto para validação quanto para documentação automática

- **Middleware:** Diretório preparado para adição futura de rate limiting, logging centralizado e autenticação

3.3 Ciclo de Vida da Aplicação (Lifespan)

A API utiliza o padrão lifespan do FastAPI para gerenciar recursos durante todo o ciclo de vida do servidor:

Startup (inicialização):

- Configura logging estruturado com timestamp e nível de severidade
- Cria diretórios necessários via `setup_directories()`
- Instancia o `AgentManager` com limites configuráveis (100 sessões, TTL de 60 minutos)
- Armazena o `AgentManager` em `app.state` para acesso por todos os endpoints

Shutdown (encerramento):

- Executa `cleanup()` do `AgentManager`, removendo todas as sessões ativas
- Libera memória dos agentes (`clear_memory` de cada instância)

4. Sistema de Gerenciamento de Sessões

4.1 Conceito: Uma Sessão, Um Agente

O design fundamental da API baseia-se no princípio de isolamento por sessão: cada sessão de chat no frontend recebe sua própria instância do `RegenerationCreditAgent`, com memória conversacional completamente independente. O `VectorStore ChromaDB`, por sua vez, é compartilhado em modo leitura entre todas as sessões.

```
Sessao 1 --> Agente 1 (memoria propria) --+
Sessao 2 --> Agente 2 (memoria propria) --+--> VectorStore ChromaDB
Sessao N --> Agente N (memoria propria) --+ (compartilhado, 120+ docs)
```

Essa abordagem garante que conversas de diferentes usuários não interfiram entre si, enquanto evita duplicação da base de conhecimento (que é a parte mais pesada em termos de memória).

4.2 AgentManager: Pool Thread-Safe

O `AgentManager` é a classe central responsável pela gestão do ciclo de vida das sessões. Suas responsabilidades incluem:

- Criação de sessões: Instancia um novo `RegenerationCreditAgent` com UUID único
- Acesso thread-safe: Utiliza `threading.Lock` para proteger o dicionário interno de sessões contra condições de corrida em ambiente multi-thread
- Limite de sessões: Máximo de 100 sessões simultâneas (configurável). Ao atingir o limite, a sessão mais antiga é automaticamente removida (eviction)
- Cleanup no shutdown: Remove todas as sessões e libera memória dos agentes ao encerrar o servidor

4.3 TTL e Expiração Automática

Sessões inativas por mais de 60 minutos são automaticamente expiradas. A implementação segue um padrão lazy (preguiçoso): não existe um timer periódico verificando expiração. Em vez disso, a limpeza ocorre durante operações normais — quando uma nova sessão é criada ou quando um agente é acessado.

Cada interação com uma sessão (mensagem enviada, histórico consultado) executa `session.touch()`, atualizando o timestamp de última atividade. Isso garante que sessões ativas nunca sejam removidas prematuramente.

Parâmetros configuráveis:

Parâmetro	Padrão	Descrição
<code>max_sessions</code>	100	Máximo de sessões simultâneas no pool
<code>ttr_minutes</code>	60	Tempo de inatividade até expiração (minutos)

4.4 Identificação por UUID

Cada sessão é identificada por um UUID v4 gerado automaticamente no momento da criação (exemplo: 4fa9635-607d-45c8-a23b-c1f23f6f05b0). O frontend armazena este identificador e o reenvia em todas as requisições subsequentes, garantindo continuidade da conversa e acesso à memória correta do agente.

5. Endpoints da API

5.1 Visão Geral dos Endpoints

Todos os endpoints estão sob o prefixo `/api/v1`, seguindo boas práticas de versionamento de API. A tabela a seguir resume os endpoints disponíveis:

Método	Endpoint	Descrição
GET	<code>/api/v1/health</code>	Health check do serviço
POST	<code>/api/v1/sessions</code>	Criar nova sessão de chat
GET	<code>/api/v1/sessions/{id}</code>	Metadados da sessão
GET	<code>/api/v1/sessions/{id}/history</code>	Histórico de mensagens
DELETE	<code>/api/v1/sessions/{id}</code>	Encerrar sessão
POST	<code>/api/v1/chat</code>	Enviar mensagem ao chatbot
WS	<code>/api/v1/ws/chat/{id}</code>	Chat em tempo real (WebSocket)

5.2 Health Check

O endpoint `GET /api/v1/health` permite monitoramento do estado do serviço. Retorna status do servidor, versão da API, número de sessões ativas e estado do VectorStore. Útil para integração com sistemas de monitoramento e alertas.

5.3 Gerenciamento de Sessões

O ciclo de vida de uma sessão segue um padrão CRUD simplificado:

- `POST /sessions`: Cria nova sessão, retorna `session_id` (UUID) e timestamp de criação
- `GET /sessions/{id}`: Consulta metadados (data de criação, última atividade, contagem de mensagens)
- `GET /sessions/{id}/history`: Retorna histórico completo de mensagens trocadas (role + content)
- `DELETE /sessions/{id}`: Encerra a sessão, libera o agente e memória associada

5.4 Endpoint de Chat (Detalhe)

O `POST /api/v1/chat` é o endpoint principal da API. Recebe uma mensagem do usuário vinculada a uma sessão ativa e retorna a resposta completa do chatbot com metadados detalhados:

Request:

```
POST /api/v1/chat
Content-Type: application/json

{
  "session_id": "4faff635-607d-45c8-a23b-c1f23f6f05b0",
  "message": "O que é o Regeneration Credit?"
}
```

Response:

```
{
  "success": true,
  "session_id": "4faff635-...",
  "response": "O Regeneration Credit é um sistema...",
  "timestamp": "2026-03-25T17:07:30.123456",
  "elapsed_seconds": 6.60,
  "tokens": {
    "total": 8251,
    "custo_formatado": "$0.0104",
    "tokens_formatado": "8.2K"
  },
  "stats": {
    "total_chamadas_llm": 2,
    "iterations": 2,
    "tool_calls": 1
  }
}
```

A resposta inclui não apenas o texto gerado pelo chatbot, mas também métricas operacionais (tokens consumidos, custo estimado, tempo de processamento) e estatísticas do loop ReAct (iterações, chamadas de ferramentas). Esses dados permitem ao frontend exibir indicadores de performance e ao time técnico monitorar custos.

5.5 WebSocket para Chat em Tempo Real

Como alternativa ao endpoint REST, a API oferece suporte a WebSocket no caminho `WS /api/v1/ws/chat/{session_id}`. Essa opção é ideal para uma experiência de chat mais fluida, onde a conexão permanece aberta e mensagens são trocadas bidireccionalmente sem a sobrecarga de estabelecer nova conexão HTTP a cada interação.

O fluxo do WebSocket funciona da seguinte forma: o cliente conecta usando um `session_id` válido, envia mensagens como texto puro (string) e recebe respostas no mesmo formato JSON do endpoint REST.

5.6 Schemas Pydantic

Todos os modelos de request e response são definidos como classes Pydantic no módulo `api/models/schemas.py`. Isso garante:

- Validação automática de entrada (tipos, limites, campos obrigatórios)
- Serialização/deserialização JSON consistente
- Documentação OpenAPI gerada automaticamente a partir dos type hints
- Mensagens de erro claras quando a validação falha (código 422)

Modelos definidos:

Modelo	Tipo	Uso
ChatRequest	Request	Mensagem do usuário (session_id + message)
ChatResponse	Response	Resposta completa com tokens e stats

TokensInfo	Response (nested)	Detalhamento de consumo de tokens
StatsInfo	Response (nested)	Estatísticas do loop ReAct
SessionCreateResponse	Response	Confirmação de criação de sessão
SessionInfoResponse	Response	Metadados da sessão
SessionHistoryResponse	Response	Histórico de mensagens
HealthResponse	Response	Status do serviço
ErrorResponse	Response	Formato padronizado de erros

6. Segurança e Configuração

6.1 CORS (Cross-Origin Resource Sharing)

A API configura CORS para permitir que o frontend Next.js acesse os endpoints a partir de domínios diferentes. As origens permitidas são:

Origem	Ambiente
https://regenerationcredit.org	Produção
https://www.regenerationcredit.org	Produção
http://localhost:3000	Desenvolvimento (Next.js)
http://localhost:3001	Desenvolvimento (alternativo)
http://127.0.0.1:3000	Desenvolvimento (alternativo)

Novos domínios podem ser adicionados editando a lista `ALLOWED_ORIGINS` em `api/main.py`. A configuração atual permite credentials, todos os métodos HTTP e todos os headers.

6.2 Validação de Entrada

A segurança de entrada é garantida em múltiplas camadas:

- `Pydantic`: Valida tipos, campos obrigatórios e limites (mensagens entre 1 e 5000 caracteres)
- `Session IDs`: Validados contra o pool ativo – requisições com IDs inválidos ou expirados retornam erro 404
- `Tratamento de exceções`: Erros internos do agente são capturados e retornados como erro 500 sem expor detalhes internos

6.3 Configurações Operacionais

O servidor pode ser configurado via linha de comando (`argparse`) ou variáveis de ambiente:

Parâmetros de inicialização:

Parâmetro	Padrão	Descrição
<code>--host</code>	0.0.0.0	Host do servidor
<code>--port</code>	8000	Porta do servidor
<code>--reload</code>	false	Auto-reload em desenvolvimento
<code>--workers</code>	1	Workers do Uvicorn
<code>--log-level</code>	info	Nível de log (debug, info, warning, error)

Variáveis de ambiente (arquivo `.env`):

Variável	Obrigatória	Descrição
ANTHROPIC_API_KEY	Sim	Chave da API Anthropic para o LLM
LANGCHAIN_API_KEY	Não	Chave do LangSmith (observabilidade)
LANGCHAIN_PROJECT	Não	Nome do projeto no LangSmith

6.4 Decisão: Workers = 1

Uma decisão técnica importante é manter o número de workers do Uvicorn em 1. Os agentes vivem em memória (dicionário Python) e não em um banco de dados externo. Múltiplos workers criariam processos independentes, cada um com seu próprio pool de sessões — uma sessão criada no Worker A não seria encontrada pelo Worker B. Para escalar horizontalmente, seria necessário externalizar o estado das sessões (por exemplo, usando Redis), o que está planejado como evolução futura.

6.5 Itens de Segurança Planejados

Os seguintes itens de segurança estão planejados para fases futuras e já possuem estrutura preparada (diretório middleware/):

- **Autenticação JWT:** Tokens de autenticação para garantir que apenas usuários válidos acessem o chatbot
- **Rate Limiting:** Limitar número de requisições por IP/sessão para prevenir abuso
- **API Keys:** Chaves de acesso para integração programática por terceiros

7. Integração com o Frontend Next.js

7.1 Fluxo de Integração

O fluxo típico de integração entre o frontend Next.js e a API segue um padrão simples de 4 etapas:

1. Usuario abre o widget de chat
+---> Frontend chama POST /sessions
+---> Recebe session_id
2. Usuario digita mensagem e envia
+---> Frontend chama POST /chat com { session_id, message }
+---> Exibe "carregando..." enquanto aguarda
+---> Recebe resposta JSON
+---> Renderiza response (Markdown) no chat
3. Repetir passo 2 para cada mensagem
(a memoria conversacional e mantida no servidor)
4. Usuario fecha o chat ou sai da pagina
+---> Frontend chama DELETE /sessions/{session_id}
(opcional - sessoes expiram sozinhas em 60min)

7.2 Exemplos de Código Fornecidos

Para acelerar a integração, foram desenvolvidos e documentados exemplos de código prontos para uso no projeto Next.js:

Módulo chatbot-api.ts:

Módulo TypeScript completo com funções tipadas para todas as operações da API: createSession(), sendMessage(), getHistory(), deleteSession() e healthCheck(). Utiliza axios (já presente no projeto Next.js) e define interfaces TypeScript que espelham os schemas Pydantic da API.

Componente ChatWidget.tsx:

Componente React funcional completo e estilizado com Tailwind CSS que implementa um widget de chat flutuante. Inclui gerenciamento de estado com React hooks (useState, useEffect, useRef), criação automática de sessão ao abrir, scroll automático, indicador de carregamento e renderização de Markdown nas respostas.

Integração WebSocket:

Exemplo de módulo chatbot-ws.ts que encapsula a comunicação WebSocket, fornecendo uma interface simplificada com callbacks para mensagens recebidas e erros.

7.3 Documentação Automática

Após iniciar a API, a documentação interativa fica automaticamente disponível em:

- Swagger UI: <http://localhost:8000/api/v1/docs> – interface interativa para testar endpoints diretamente no navegador

- ReDoc: <http://localhost:8000/api/v1/redoc> – documentação formatada para leitura
- OpenAPI JSON: <http://localhost:8000/api/v1/openapi.json> – especificação OpenAPI 3.0 para geração automática de clientes

Adicionalmente, foi criado o arquivo `API_README.md` (706 linhas) com documentação completa incluindo exemplos de requisição/resposta, códigos de erro, instruções de instalação e exemplos de integração em TypeScript.

8. Notas Técnicas e Reaproveitamento do Core

8.1 Reaproveitamento Total do Núcleo de IA

Um dos pontos mais relevantes desta fase é que a API não duplica nenhuma lógica de IA. O mesmo `RegenerationCreditAgent` desenvolvido na Parte I é reutilizado integralmente. A API é apenas uma nova "porta de entrada" para o sistema:

- `RegenerationCreditAgent`: Loop `ReAct`, `system prompt`, decisão de ferramentas – inalterado
- Ferramentas RAG: `search_general`, `search_whitepaper`, `search_contracts`, `consult_tokenomics_guide` – reutilizadas diretamente
- `VectorStore ChromaDB`: Mesma base de conhecimento com 120+ documentos indexados
- `TokensTracker`: Tracking de tokens e custos preservado, com dados expostos na resposta JSON da API
- `Pricing Calculator`: Cálculos de custo mantidos e retornados ao frontend

Essa abordagem garante consistência de comportamento entre as duas interfaces (Streamlit e API) e minimiza o risco de regressões.

8.2 Tratamento de Erros

A API implementa tratamento de erros padronizado em todas as camadas:

Código	Descrição	Quando Ocorre
200	Sucesso	Requisição processada com sucesso
201	Criado	Nova sessão criada
404	Não encontrado	<code>session_id</code> inválido ou sessão expirada
422	Validação	Campos obrigatórios ausentes ou fora dos limites
500	Erro interno	Falha no agente IA ou no servidor

Todas as respostas de erro seguem um formato consistente com campo "detail" descritivo. Logs internos incluem prefixo do `session_id` (primeiros 8 caracteres) para rastreabilidade.

8.3 Stack Tecnológico Adicionado

A seguinte stack foi adicionada ao projeto nesta fase, complementando as tecnologias já existentes documentadas na Parte I:

Tecnologia	Versão	Função
FastAPI	latest	Framework web async para a API REST
Uvicorn	latest (standard)	Servidor ASGI de alta performance

WebSockets	latest	Suporte a chat em tempo real
Pydantic	2.10.6	Validação de dados e schemas (já existia)

9. Evolução do Sistema: Antes e Depois

A tabela a seguir sintetiza a evolução do sistema entre a Parte I (interface Streamlit) e a Parte II (API REST), evidenciando os avanços em cada dimensão:

Aspecto	Parte I (Streamlit)	Parte II (API REST)
Interface	Acoplada (Python/Streamlit)	Desacoplada (qualquer frontend)
Protocolo	HTTP (Streamlit server)	HTTP REST + WebSocket
Sessões	st.session_state (por aba)	AgentManager com UUID e TTL
Concorrência	Single-thread	Multi-thread (asyncio.to_thread)
Documentação da API	Manual / inexistente	Auto-gerada (Swagger/ReDoc)
Clientes suportados	Apenas browser (Streamlit)	Web, mobile, API programática
Validação de entrada	Validação manual	Automática (Pydantic)
Expiração de sessões	Enquanto aba aberta	TTL configurável (60min)
Estágio	POC / Beta	Pronto para integração

A interface Streamlit continua disponível como ferramenta de desenvolvimento, debug e demonstração.

A API REST é a interface recomendada para produção e integração com o frontend Next.js.

10. Próximos Passos

Com a API REST implementada e funcional, o projeto avança para as próximas fases de evolução. Os itens abaixo seguem em ordem de prioridade:

10.1 Integração Efetiva com o Frontend

Prioridade: Alta

Implementar o widget de chat no site regenerationcredit.org utilizando os exemplos de código fornecidos (ChatWidget.tsx, chatbot-api.ts). Inclui estilização alinhada à identidade visual do projeto, testes de usabilidade e otimização de performance (lazy loading do widget, compressão de respostas).

10.2 Autenticação e Segurança

Prioridade: Alta

Implementar autenticação JWT para proteger os endpoints da API, garantindo que apenas usuários válidos do site possam acessar o chatbot. Adicionar rate limiting por IP e sessão para prevenir abuso e controlar custos operacionais.

10.3 Escalabilidade e Deploy

Prioridade: Média

Externalizar o estado das sessões (usando Redis ou banco de dados) para permitir múltiplos workers e escalabilidade horizontal. Containerizar a aplicação com Docker para deploy consistente e reprodutível. Configurar um pipeline de CI/CD para deploy automatizado.

10.4 Testes Automatizados da API

Prioridade: Média

Desenvolver suíte de testes utilizando o TestClient do FastAPI para validação dos endpoints (testes unitários), testes de integração com agente mock e testes de carga para validar comportamento sob concorrência. A estrutura atual já inclui pytest no requirements.txt.

10.5 Monitoramento em Produção

Prioridade: Média

Implementar dashboard de monitoramento com métricas de latência, consumo de tokens, custos por sessão, taxa de erros e sessões ativas. O LangSmith já oferece parte dessa funcionalidade; complementar com métricas customizadas do AgentManager.

10.6 Aprimoramentos do Sistema RAG

Prioridade: Contínua

Conforme definido no roadmap da Parte I, continuar evoluindo o sistema RAG com re-ranking de resultados, filtros adaptativos, cache de embeddings e otimização de chunk size. Estas melhorias beneficiam tanto a API quanto a interface Streamlit, pois compartilham o mesmo núcleo.

11. Conclusão

A criação da API REST concretiza o item (ii) do roadmap definido no relatório anterior — Integração com Aplicativo Regeneration Credit — e representa um marco significativo na evolução do projeto.

Principais conquistas desta fase:

- Desacoplamento: O chatbot evoluiu de uma POC com interface Streamlit para um serviço backend independente e integrável com qualquer frontend
- Reaproveitamento: 100% do núcleo de IA foi reutilizado sem duplicação — a API é apenas uma nova porta de entrada para o mesmo agente, ferramentas RAG e base de conhecimento
- Arquitetura sólida: Gerenciamento de sessões com TTL, concorrência via `asyncio.to_thread`, validação automática com Pydantic e documentação auto-gerada via OpenAPI
- Pronto para integração: Exemplos de código TypeScript/React fornecidos, configuração CORS preparada para o domínio de produção, e documentação completa de 706 linhas
- Base para evolução: Estrutura preparada para adição de autenticação, rate limiting, escalabilidade horizontal e monitoramento

O caminho está aberto para a próxima fase: a integração efetiva com o frontend Next.js do Regeneration Credit. Com a API funcional, documentada e testada, a equipe de frontend possui todos os recursos necessários para implementar o widget de chat no site, transformando o assistente IA de uma ferramenta interna em um recurso acessível a todos os usuários do projeto.