interweb

Gerado a 15/11/2026 01:59

BASE DE CONHECIMENTO · DOCUMENTO PÚBLICO

IA que responde a partir dos seus documentos: o RAG explicado

Como funciona a IA

CÓDIGO
RLX-MZ-KB-964

VERSÃO
v2026.10.18

PAÍS · IDIOMA
Moçambique · Português

Interweb Moçambique
RLX Holdings, S.A. · Grupo RLX Holdings
NUIT 401 191 607 · NUEL 105 045 974 · CAE 62022

https://www.meu.interweb.co.mz/knowledgebase/964

IA que responde a partir dos seus documentos: o RAG explicado

Como funciona a IA Criado em **10 de outubro de 2026** Atualizado em **18 de outubro de 2026** 3 min de leitura

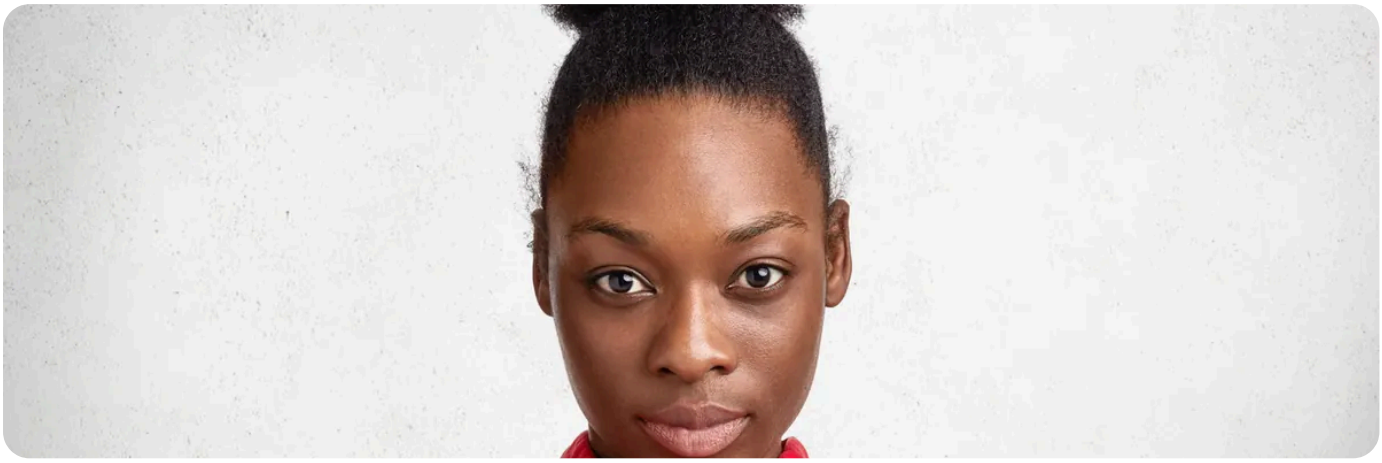

RAG (geração com recuperação, em inglês *retrieval-augmented generation*) é a técnica por trás de quase todos os assistentes que «respondem com base nos nossos documentos». Em vez de treinar um modelo com os seus textos, o sistema **procura os excertos relevantes e entrega-os ao modelo junto com a pergunta**. O modelo responde a partir deles. Reduz as respostas inventadas, mas não as elimina.

Como funciona, em cinco passos

1. **Reúnem-se os documentos:** as perguntas frequentes, as páginas do site, os manuais, os contratos-tipo.
2. **Cortam-se em pedaços** pequenos, de modo que cada um trate de uma coisa.
3. **Cada pedaço é transformado em números** (um «*embedding*») que representam o seu sentido, por um modelo próprio para isso. Textos com significado parecido ficam com números parecidos.
4. **Guardam-se numa base de dados própria para pesquisa por sentido** (uma base vectorial). Algumas bases comuns têm uma extensão para isto.
5. **Quando alguém pergunta,** a pergunta também vira números, o sistema vai buscar os pedaços mais próximos e entrega-os ao modelo com a instrução «responde só com base nisto».

RAG ou outra coisa

Abordagem	Serve para	Limite
Colar o texto na conversa	Um documento, uma vez	Não escala, e paga-se o texto inteiro em cada pedido

Abordagem	Serve para	Limite
RAG	Muitos documentos, que mudam, e perguntas variadas	Só é tão bom como os documentos e a forma de os cortar
Afinar um modelo (*fine-tuning*)	Ensinar um estilo ou um formato	Não é uma boa maneira de lhe ensinar factos que mudam

O que precisa para o montar

1. **Os documentos, limpos e actuais.** Se a política mudou e o documento antigo continua lá, o assistente cita-o.

2. **Um modelo de embeddings e um modelo de resposta,** de um fornecedor ou corridos por si. Veja **obter uma chave de API**.

3. **Um sítio onde guardar os vectores.** Um serviço pronto, ou uma base de dados sua com a extensão adequada. Se a instalar num VPS, veja **instalar o PostgreSQL num VPS** e confirme se a versão suporta a extensão que escolher.

4. **A cola entre tudo.** Uma aplicação sua ou um fluxo numa ferramenta como o n8n. Veja **o que é o n8n**.

Cuidado com quem pode ver o quê.

Se pôr no mesmo índice documentos públicos e internos, o assistente pode citar os internos a qualquer pessoa. Separe os índices ou controle o acesso por utilizador.

Ainda pode inventar.

Se os excertos não trazem a resposta, um modelo mal instruído completa com o que «sabe». Mande-o dizer «não encontrei» e mostre sempre de que documento veio a resposta. Veja **alucinações de IA**.

Comece com poucos documentos e uma lista de perguntas de teste cuja resposta conhece. Se não acerta nessas, não está pronto para os clientes.

RECOMENDADO

Quer pôr um assistente destes num VPS seu? Veja os planos e escolha o tamanho.

Ver planos de VPS →

VEJA TAMBÉM

- **Pôr um assistente de IA a conversar no seu site**
- **Tokens explicados: como se contam as APIs de IA**
- **Instalar o PostgreSQL num VPS**
- **Um agente de IA precisa de um VPS, não de hospedagem partilhada**

interweb

Interweb Moçambique

RLX Holdings, S.A. · Grupo RLX Holdings

NUIT	401 191 607
NUEL	105 045 974
CAE	62022
SEDE	Bairro 7 de Setembro Vilankulo 1304 · CEP 0411-02, Inhambane, Moçambique
CONTACTOS	info@interweb.co.mz · +258 84 635 1111 · +258 86 635 1111 · www.interweb.co.mz
HORÁRIO	2ª. à 6ª. Feira - 08 à 16 Horas Sábado & Domingo - Fechado

Versão online deste documento

RLX-MZ-KB-964 · v2026.10.18 · Gerado a 15/11/2026 01:59